

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

**SAMOORGANIZIRANJE NEIZRAZITOG
ANALITIČKOG REGULATORA PRI
VOĐENJU MOBILNOG ROBOTA**

DOKTORSKI RAD

Mr.sc. Marijo Kirola

ZAGREB, 2005

PODACI ZA BIBLIOGRAFSKU KARTICU:

UDK: **681.532:007.5**

Ključne riječi: **postupak samoorganiziranja, nelinearni algoritam adaptacije, neizrazito upravljanje uz analitički pristup.**

Znanstveno područje: **TEHNIČKE ZNANOSTI**

Znanstveno polje: **Strojarstvo**

Institucija u kojoj je rad izrađen: **Fakultet strojarstva i brodogradnje**

Mentor rada: **Prof. dr. sc. Branko Novaković**

Broj stranica: **157**

Broj slika: **130**

Broj tablica: **8**

Broj korištenih bibliografskih jedinica: **89**

Datum obrane:

Povjerenstvo: **Dr.sc. Božo Vranješ
Dr.sc. Branko Novaković
Dr.sc. Mladen Crneković
Dr.sc. Zdravko Terze
Dr.sc. Zoran Vukić**

Institucija u kojoj je rad pohranjen: **FSB SZG**

ZAHVALA

Na početku razrade teme ove doktorske disertacije, zahvaljujem se svim osobama koje su me podržale i imale razumijevanja tijekom njene izrade.

Najveću zahvalnost dugujem početniku suvremenog analitičkog pristupa u neizrazitoj logici svom mentoru ***prof.dr.sc Branku Novakoviću***, kako na podršci i razumijevanju pri izboru teme doktorske disertacije tako i na znanstvenoj pomoći i savjetima tijekom njene izrade.

Ovom prilikom zahvaljujem rektoru novoosnovanog sveučilišta u Dubrovniku (SDU) ***prof.dr.sc Mateu Milkoviću*** na ustrajaloj potpori i podršci prilikom izrade ove doktorske disertacije, nadajući se da će naša suradnja i nakon izrađene doktorske disertacije biti isto tako plodonosna, ako ne i plodonosnija nego što je prije bila. Isto tako se toplo nadam da će nakon njene izrade imati dovoljno razumijevanja za moje potrebe, kako bi moj rad i ljubav prema robotici, mehatronici i automatskoj regulaciji zadržala svoju kontinuiranost i dosljednost te doprinjela tehničkom razvoju sveučilišta u Dubrovniku.

Zahvalnost na razumijevanju i pomoći dugujem i svim članovima strojarskog odjela pomorskog fakulteta SDU.

Ipak najveću zahvalnost dugujem svojoj *majci*, koja mi je pružala svakodnevnu podršku i pomoć da ova disertacija ugleda svjetlost dana i da ovaj moj san postane realnost.

SADRŽAJ

Predgovor	VI
Sažetak	XIII
Summary	IX
Popis oznaka	X
Popis slika	XVI
Popis tablica	XXX
Popis akronima (kratica)	XXXI
 1. Uvod	 1
1.1. Povijesni osvrt razvoja konvencionalne neizrazite logike	1
1.2. Suvremeni analitički pristup u razvoju neizrazite logike	2
1.3. Definiranje problema suvremenog analitičkog pristupa neizrazite regulacije	4
1.4. Razrada postavljenog problema po poglavljima	5
1.5. Hipoteza rada	7
2. Suvremeni neizraziti analitički regulator	8
2.1. Osnovni pojmovi neizrazitog analitičkog regulatora	8
2.1.1. Novi oblik funkcije pripadnosti neizrazitom skupu	8
2.1.2. Normalizacija ulazne varijable	10
2.1.3. ε - β distribucija raščlanjenosti ulaznih neizrazitih skupova	11
2.1.4. Analitički oblik aktivacijske funkcije i funkcije preslikavanja za određivanje položaja centara izlaznih neizrazitih skupova	13
2.2. Osnovna svojstva i smjernice u razvoju analitičkog pristupa neizrazitoj regulaciji	15
2.3. Struktura neizrazitog analitičkog regulatora	18
2.4. Struktura poboljšanog neizrazitog analitičkog regulatora	20
2.4.1. Postupak Decimalno-Neizrazite (D/N) pretvorbe	20
2.4.2. Postupak odlučivanja (inferencije)	22
2.4.3. Postupak Neizrazito-Decimalne (N/D) pretvorbe	25
2.5. Analiza utjecaja slobodnog F , β i γ_I parametra preko fazne ravnine stanja	27
2.6. Stupanj neizrazitog djelovanja η poboljšanog neizrazitog analitičkog regulatora	31
3. Početno podešavanje poboljšanog neizrazitog analitičkog regulatora	46
3.1. Rezultati simulacije vođenja mobilnog robota sa početno podešenim PD-PNAR -om ..	54
4. Postupak samoorganiziranja poboljšanog neizrazitog analitičkog regulatora	66
4.1. Proces adaptacije slobodnih parametara PNAR -a	67

4.2. Rezultati simulacije vođenja mobilnog robota referentnom putanjom složenog oblika u prostoru upravljanih koordinata	77
4.3. Usporedba djelovanja PD-PNAR -a sa klasičnim PD -regulatorom	83
4.4. Stabilnost algoritma adaptiranja	87
5. Poboľšani neizraziti analitički regulator (PNAR) kao nelinearni diskretni (PD , PI i PID) regulator	93
5.1. Nelinearni PD-PNAR i poremećaji tipa početnog uvjeta	94
5.2. Adaptiranje PD-PNAR -a	99
5.3. Stabilnost predloženog algoritma samoorganiziranja PD-PNAR -a	103
5.4. Uvjeti stabilnosti algoritma regulacije	106
5.5. Nelinearni PI i PID-PNAR i konstantni nemjerljivi poremećaji (podešavanje integralnog pojačanja)	107
5.6. Strukture samoorganiziranja PNAR -a	117
6. PNAR prilagođen ON -line vođenju mobilnog robota u realnom vremenu	120
6.1. Rezultati simulacije ON -line vođenja mobilnog robota u realnom vremenu sa implementiranom MKNUD -a	125
6.2. Rezultati simulacije ON -line vođenja mobilnog robota u realnom vremenu sa implementiranom MKNUD -a i izrazito nelinearnim PI -regulatorom	128
6.3. ON -line vođenje mobilnog robota u realnom vremenu uz djelovanje stacionarnog poremećaja tipa »bijelog šuma«	131
6.4. ON -line vođenje mobilnog robota u realnom vremenu uz djelovanje nestacionarnog poremećaja tipa »bijelog šuma«	151
7. Glavni rezultati rada.....	155
8. Zaključak doktorskog rada	157
Literatura	XXXIII
Životopis	XXXVIII
Biography	XXXIX
Popis priloga	XL
Prilog 1	XLI
Prilog 2	XLIV
Prilog 3	XLVI
Prilog 4	XLVIII
Prilog 5	L
Prilog 6	LII
Prilog 7	LIII
Prilog 8	LIV

PREDGOVOR

Život na zemlji svakodnevno je okružen mnogim neizrazitim promjenama, djelovanjima, pojavama i očekivanjima. Pri tome se pod neizrazitim promjenama podrazumijeva stupnjevana ili djelomična promjena stanja koja se može, ali ne mora pod određenim uvjetima izvršiti. Neizrazitost kao kvalitativna slika u fleksibilnom razlučivanju onoga što jest od onoga što nije sve se više uvlači u pore ljudskog života i djelovanja, tako da i sami često nesvjesno postajemo svjedoci njezine svakodnevne prisutnosti u našem životu. Teorija neizrazite logike svoju punu afirmaciju pronalazi u Japanskoj kulturi, gdje npr. riječ »DA« znači sve u rasponu između potvrđivanja i nepotvrđivanja. Kao i prema svakoj drugoj novoj začetij teoriji i ovdje postoji određeni skepticizam čije razloge treba tražiti u kulturi zapadnih zemalja koja poštuje sve što je kvantitativno i precizno a sa sumnjom gleda i odbacuje sve ono novo što pokušava ući u harmoniju sa stohastičkim događajima realnog svijeta. Teorija neizrazite logike sve se više uvlači u već postavljene teorije koje u određenom stupnju svoje egzaktnosti u potpunosti ne zadovoljavaju u svom području. Tako u poznatoj teoriji »kaosa« u kojoj se traga za uzročno posljedičnim vezama nekih neriješenih prirodnih pojava, sada je omogućeno postavljanje novih hipoteza zahvaljujući upravo afirmaciji umjetnih neuronskih mreža, genetskih algoritama i neizrazite logike za koju je ponajprije zaslužan Lotfi Zadeh, Amerikanac azerbejdžanskog porijekla koji je 1965. godine postavio osnovne temelje teorije neizrazitih skupova [2]. Od tada pa do danas teorija neizrazitih skupova je našla svoju primjenu u mnogim područjima važnim za ljudski život kao što su procesna i automobilska industrija, transportni sustavi, ekologija, zabavna elektronika, ekonomija, turizam i ugostiteljstvo. Osnovni nedostatak konvencionalnog pristupa neizrazitoj regulaciji, ogleda se u tome što se sa povećanjem broja ulaznih varijabli, eksponencijalno povećava broj potrebnih pravila regulacije neizrazitog regulatora. Razvojem suvremenog analitičkog pristupa neizrazitoj regulaciji [30], nadilazi se taj problem uvođenjem analitičke funkcije preslikavanja ulaznih neizrazitih skupova na poziciju centra izlaznih neizrazitih skupova. Takav analitički pristup svoju primjenu pronalazi u vođenju nepokretnih i pokretnih robotskih sustava, te u regulacijskim krugovima alatnih strojeva i fleksibilnih proizvodnih sustava. U magistarskom radu [40] provedena je implementacija neizrazitog analitičkog algoritma upravljanja sa svrhom vođenja autonomnog mobilnog robotskog sustava po unaprijed definiranoj nominalnoj trajektoriji, zadanoj od strane višeg strateškog nivoa upravljanja. Napravljena je usporedba sa klasičnim upravljačkim sustavom [38], uz istaknute dobre strane neizrazite regulacije. Slobodni parametri neizrazitog analitičkog regulatora određivali su se intuitivno, dugotrajnim i mukotrpnim procesom koji obuhvaća interaktivni rad

sa računalom, kako bi se ovisno o dinamici vođenog sustava pronašle najprikladnije vrijednosti tih parametara. Stoga odavde proizlazi i osnovna motivacija u postavljanju hipoteze i razrade postavljenog zadatka izradom ove doktorske disertacije. Nastoji se poboljšati postojeća struktura neizrazitog analitičkog regulatora koja se razvija u pravcu inteligentnog djelovanja u smislu obučavanja, odnosno samoorganiziranja njezinih slobodnih parametara.

Dubrovnik, 10. listopada, 2005.

Kirola, M.

SAŽETAK

U ovoj doktorskoj disertaciji predlaže se novi analitički oblik funkcije pripadnosti ulaznih neizrazitih skupova i novi oblik analitičke funkcije za preslikavanje ulaznih neizrazitih skupova na pozicije centara izlaznih neizrazitih skupova. Promjenom osnovne strukture, povećava se neizrazito područje djelovanja neizrazitog analitičkog regulatora, čime su mogućnosti u procesu inferencije poboljšane. U faznoj ravnini stanja provedena je analiza utjecaja slobodnih parametara na formiranje prostora neizrazitog djelovanja, i utemeljen je prijedlog po kojemu »Dovoljan broj slobodnih parametara neizrazitog logičkog regulatora može aproksimirati bilo koju nepoznatu analitičku funkciju«. Predložen je postupak početnog podešavanja neizrazitog regulatora bez baze pravila regulacije koji je pokazao dobru emulaciju klasičnog PD i PI regulatora. S obzirom na gradijent pogreške slijeđenja nominalne trajektorije u prostoru unutarnjih koordinata predložen je u OFF-line modu rada postupak samoorganiziranja slobodnih parametara suvremenog neizrazitog regulatora. S obzirom na brzinu konvergencije i stabilnost nelinearnog algoritma samoorganiziranja postavljena su ograničenja na koeficijente obučavanja, kao i ograničenja koja prema Lyapunovu trebaju biti zadovoljena da bi se osigurala stabilnost algoritma upravljanja. Poboljšanim neizrazitim analitičkim regulatorom realizirane su nelinearne diskretne strukture sa integralnim djelovanjem u sklopu kojih je predložen i algoritam podešavanja integralnog pojačanja. Da bi se osiguralo ON-line vođenje autonomnog mobilnog robota u realnom vremenu, predložena je zamjena strukture samoorganizirajućeg neizrazitog regulatora sa diskretnim podacima zapisanim u memorijskoj kartici neizrazitog upravljačkog djelovanja. Na osnovu pogreške pozicije u uvjetima stacionarne i nestacionarne mjerne smetnje tipa »bijelog šuma« predložen je neizraziti mehanizam podešavanja slobodnih parametara poboljšanog neizrazitog analitičkog regulatora i pojačanja klasičnog PI-regulatora i kako bi se učinio kompromis između smanjenja utjecaja mjerne smetnje i povećanja brzine estimacije upravljanih varijabli. Ispravnost svih predloženih postupaka, provjerena je simulacijom vođenja autonomnog mobilnog robota zadanom nominalnom trajektorijom složenijeg oblika.

KLJUČNE RIJEČI:

Autonomni mobilni robot,
Neizraziti logički regulator bez baze pravila regulacije,
Postupak samoorganiziranja,
Nelinearni algoritam adaptacije,
Neizraziti skupovi,
Funkcija pripadnosti,
Referentna (nominalna) trajektorija.

SUMMARY

In this work new analytical form of membership function of input fuzzy sets and a new form of analytical function for mapping of input fuzzy sets on positions of centres of output fuzzy sets is suggested. By changing of basic structure, fuzzy domain of fuzzy analytical controller is increasing, thus resulting in a fact that possibilities in process of interference were improving. In the phase plane of condition, impact analysis of free parameters on forming of space of fuzzy action is realised, and proposition by which „Sufficient number of free parameters of fuzzy logic controllers can approximate any unknown analytical function“ is founded. The method of the starting adjustment of fuzzy logic controllers without a fuzzy rule base which showed good emulation of classic PD and PI controller is suggested. With regard to gradient of tracking error of nominal trajectory in space of inner coordinates in OFF-line mode, method of selforganising which include adaptations of free parameters of contemporary fuzzy logic controllers is suggested. In respect of convergence speed and stability of nonlinear algorithm of adaptation, restriction on coefficient of training are made, and also restrictions, which, according Lyapunov, should be satisfied to ensure stability of control algorithm. By improved fuzzy analytical controller nonlinear structure are realised, with integral action in scope of which algorithm of integral strengthening is suggested. To assure ON-line leading of autonomous mobile robot in real time, change of analytical structure of fuzzy controller with discrete data written in memory card of fuzzy control action is suggested.

On basis of position error in conditions of stationar and nonstationar measurment disturbance of „white noise“ type, fuzzy mechanism for adjusting of free parameters of improved fuzzy analytical controller and strengthening of classic PI-controller to make compromise between lowering of influences of measurment disturbance and increasing of speed estimation of controlled variables, is suggested. Correctness of all suggested methods is verified by simulation of autonomous mobile robot through specified nominal trajectory of complex shape.

KEY WORDS:

Autonomous Mobile Robot,
Fuzzy Logic Controller without a fuzzy rule base,
Method of selforganising,
Nonlinear algorithm of adaptation,
Fuzzy Set,
Membership Function,
Nominal trajectory.

POPIS OZNAKA

Rd.	Produkt	Jedinica	Značenje	
Br.	Simbol	dimenzija	mjere	
1	ε	-	-	Adaptacijski parametar ulaznih NS NAR-a
2	β	-	-	Parametar raspodjele NS NAR-a
3	S	-	-	Funkcija pripadnosti neizrazitom skupu NAR-a
4	A_j	-	-	Ulazni NS j -te ulazne varijable
5	x	-	-	Općenito oznaka za ulaznu varijablu
6	T	-	-	Baza NS
7	B_j	-	-	Izlazni NS j -te ulazne varijable
8	ω	-	-	Analitička aktivacijska funkcija NAR-a
9	Y_{cj}	-	-	Analitička funkcija preslikavanja j -te ulazne varijable na poziciju centra izlaznog NS .
10	U_m	$ML^2T^{-3}I^{-1}$	V	Maksimalna vrijednost regulacijske varijable
12	F	$M^{-1}L^{-2}T^3I^1$	V^{-1}	Slobodni parametar analitičke funkcije preslikavanja j -te ulazne varijable na poziciju centra izlaznog NS
13	α	-	-	Slobodni parametar analitičke funkcije preslikavanja j -te ulazne varijable na poziciju centra izlaznog NS
14	K_{cj}	-	-	Adaptacijsko pojačanje pozicije centra j -tog izlaznog NS
15	γ_l	-	-	Stupanj pripadnosti j -te ulazne varijable i -tom ulaznom NS
16	γ_2	-	-	Stupanj djelovanja analitičke aktivacijske funkcije
17	k_j	-	-	Faktor pojačanja j -tog izlaznog NS
18	ε_{oj}	-	-	Adaptacijski parametar j -tog izlaznog NS , NAR-a

Rd.	Br.	Simbol	Produkt dimenzija	Jedinica mjere	Značenje
19		J_m	ML^2	$Kg \cdot m^2$	Dinamički moment tromosti istosmjernog motora
20		C_M	$ML^2T^{-2}I^{-1}$	$N \cdot m \cdot A^{-1}$	Momentna konstanta istosmjernog motora reducirana na izlazno vratilo reduktora
21		C_E	$ML^2T^{-2}I^{-1}$	$V \cdot s / rad(1)$	Konstanta proporcionalnosti elektromotorne sile istosmjernog motora
22		D_m	ML^2T^{-1}	Nms/rad	Koeficijent viskoznog trenja istosmjernog motora
23		N	-	-	Prijenosni omjer reduktora
24		R	$ML^2T^{-3}I^{-2}$	Ω	Omski otpor armaturnog namota istosmjernog motora
25		$(u_m)_i$	$ML^2T^{-3}I^{-1}$	V	Upravljački napon i -tog servomotora
26		q	L^0	$rad(1)$	Kutni pomak izlaznog vratila reduktora
27		\dot{q}	T^{-1}	rad/s	Kutna brzina izlaznog vratila reduktora
28		\ddot{q}	T^{-2}	rad/s^2	Kutno ubrzanje izlaznog vratila reduktora
29		h_{ii}	ML^2	$kg \cdot m^2$	Aksijalni dinamički momenti tromosti mehanizma AMR
30		h_{ij}	KL^2	$kg \cdot m^2$	Centrifugalni dinamički momenti tromosti mehanizma AMR
31		r	L	m	Polumjer pogonskih kotača AMR
32		K_{pu}	-	-	Pojačanje naponskog pojačala snage
33		K_p	$ML^2T^{-3}I^{-1}$	V	Pojačanje pozicije konvencionalnog regulatora
34		K_v	$ML^2T^{-2}I^{-1}$	Vs	Pojačanje brzine konvencionalnog regulatora
35		K_I	$ML^2T^{-4}I^{-1}$	V/s	Integralno pojačanje konvencionalnog regulatora
36		K_n	$ML^2T^{-3}I^{-1}$	V	Zajednički par. familije karakterističnih krivulja PNAR-a

Rd.	Br.	Simbol	Produkt dimenzija	Jedinica mjere	Značenje
37		η	-	-	Stupanj neizrazitog djelovanja PNAR -a
38		K_{Fd}	$ML^2T^{-3}I^{-1}$	V	Vrijednost dinamičkog pojačanja PNAR -a
39		K_{Fe}	$ML^2T^{-3}I^{-1}$	V	Nelinearno statičko pojačanje PNAR -a
40		Θ_e	$ML^2T^{-3}I^{-1}$	V	Osjetljivost neizrazite upravljačke varijable PNAR -a o ulaznoj pogrešci
41		Θ_F	$ML^2T^{-3}I^{-1}$	V	Osjetljivost neizrazite upravljačke varijable o slobodnom F parametru PNAR -a
42		Θ_β	$ML^2T^{-3}I^{-1}$	V	Osjetljivost neizrazite upravljačke varijable o slobodnom β parametru PNAR -a
43		A	T^{-1}	s^{-1}	Matrica koeficijenata sustava AMR -a dim(4x4)
44		B	-	-	Matrica ulaza dinamičkog sustava AMR -a dim(4x2)
45		C	-	-	Matrica izlaza dinamičkog sustava AMR -a dim(2x4)
46		X	-	-	Vektor stanja dinamičkog sustava dim(4x1)
47		u_F	$ML^2T^{-3}I^{-1}$	V	Neizrazita upravljačka varijabla
48		E_y	L^2	m^2	Funkcija cilja
49		ϑ	-	-	Poopćeni slobodni parametar
50		η_u	-	-	Koeficijent obučavanja PNAR -a
51		A	-	-	Pozitivno definitna generalizirana konstanta obučavanja PNAR -a
52		σ	-	-	Pozitivno definitna generalizirana konstanta obučavanja PNAR -a

Rd.	Br.	Simbol	Produkt dimenzija	Jedinica mjere	Značenje
53		ISE	L^2T	m^2s	Integralni kriterij kvadratne pogreške
54		Ω_g	-	-	Osjetljivost upravljane varijable dinamičkog sustava o poopćenom slobodnom parametru
55		α_g	-	-	Zamah poopćenog slobodnog parametra
56		\mathbf{A}_i	T^{-1}	s^{-1}	Matrica koeficijenata i-tog servosustava dim(2x2)
57		\mathbf{B}_i	-	-	Matrica ulaza na nivou i-tog servosustava dim(2x1)
58		\mathbf{X}_i	-	-	Vektor stanja i-tog servosustava dim(2x1)
59		ζ	-	-	Kvocijent pozitivno definitne poopćene konstante obučavanja PNAR -a
60		e	L^0	rad (1)	Pogreška pozicije
61		Δe	T^{-1}	s^{-1}	Pogreška brzine
62		$\Delta^2 e$	T^{-2}	s^{-2}	Pogreška ubrzanja
63		T_D	T	s	Derivacijska vremenska konstanta
64		T_I	T	s	Integralna vremenska konstanta
65		T_S	T	s	Vrijeme uzorkovanja signala
66		$\hat{\delta}$	-	-	Poopćeni promjenjivi koeficijent obučavanja
67		δ	-	-	Poopćeni faktor brzine obučavanja
68		\mathbf{G}	-	-	Pozitivno definitna simetrična matrica
69		V	-	-	Pozitivno definitna skalarna funkcija Ljapunova
70		θ_{KI}	T	s	Osjetljivost upravljačke varijable o integralnom pojačanju

Rd.	Br.	Simbol	Produkt dimenzija	Jedinica mjere	Značenje
70	θ	$M^{-1}L^{-2}T^4I$	sV^{-1}	Osjetljivost poopćene upravljane varijable o integralnom pojačanju	
71	$\dot{\theta}$	$M^{-1}L^{-2}T^3I$	V^{-1}	Brzina osjetljivosti poopćene upravljane varijable o integralnom pojačanju	
72	$\ddot{\theta}$	$M^{-1}L^{-2}T^2I$	$V^{-1}s^{-1}$	Ubrzanje osjetljivosti poopćene upravljane varijable o integralnom pojačanju	
73	\mathbf{A}_{di}	T^{-1}	s^{-1}	Diskretna matrica koeficijenata i-tog servosustava dm(2x2)	
74	\mathbf{B}_{di}	-	-	Diskretna matrica ulaza na i-tog servosustava dim(2x1)	
75	P	-	-	Pojačanje predupravljanja	
76	T_{AD}	T	s	Vremenski period (A/D) pretvorbe signala	
77	T_{DA}	T	s	Vremenski period (D/A) pretvorbe signala	
78	T_p	T	s	Vrijeme procesiranja algoritma upravljanja	
79	$\tilde{\mathbf{Y}}$	-	-	Vektor mjernih izlaza dim(2x1)	
80	\mathbf{W}	-	-	Vektor mjernog šuma dim(2x1)	
81	\mathbf{V}	-	-	Vektor vanjskog šuma dim(2x1)	
82	\mathbf{S}	-	-	Pozitivno semidefinitna kovarijancna matrica dim(2x2)	
83	\mathbf{Z}	-	-	Kompletni slučajni vektor smetnji dim(4x1)	
84	\mathbf{Q}	-	-	Pozitivno semidefinitna simetrična matrica varijance vanjske smetnje dim(2x2)	
85	\mathbf{R}	-	-	Pozitivno definitna simetrična matrica varijance mjernog šuma dim(2x2)	

Rd.	Br.	Simbol	Produkt dimenzija	Jedinica mjere	Značenje
86		σ_R	-	-	Standardno odstupanje komponente mjernog šuma
87		σ_Q	-	-	Standardno odstupanje komponente vanjskog šuma
88		$\tilde{\mathbf{V}}$	-	-	Matrica varijance smetnje kompletnog stohastičkog procesa dim(4x4)
89		p_w	-	-	Gustoća vjerojatnosti vektora stacionarnog mjernog šuma
90		\mathbf{e}	-	-	Vektor pogreške estimacije dim(2x1)
91		$\hat{\mathbf{x}}$	-	-	Vektor procijenjenog stanja dim(2x1)
92		\mathbf{G}_0	-	-	Matrica impulsnih odziva filtera za estimaciju dom(4x4)
93		\mathbf{H}	-	-	Pozitivno semidefinitna simetrična matrica varijanci dim(4x4)
94		$\overline{\mathbf{H}}$	-	-	Pozitivno semidefinitna stacionarna matrica varijanci dim(4x4)
95		\mathbf{K}_F	-	-	Neizrazite vrijednosti Kalmanovih pojačanja dim (2x4)
96		κ_1	-	-	Iskustveni faktor pri adaptaciji β parametra
97		κ_2	-	-	Iskustveni faktor pri adaptaciji β parametra
98		w_n	-	-	Gausova funkcija slučajnog odabira vrijednosti amplituda jedinične varijance
99		\tilde{w}_i	L^0	rad (1)	Komponenta nestacionarne mjerne smetnje i-te izlazne mjerne varijable
100		$p_{\tilde{w}}$	-	-	Gustoća vjerojatnosti vektora nestacionarnog mjernog šuma

POPIS SLIKA

Br. sl.	Naziv slike	Str.
2.1	Novi oblik funkcije pripadnosti neizrazitog skupa, a) $S(x)$ i b) $S(\underline{x})$	8
2.2	Raščlanjenost ulaznih neizrazitih skupova parametrom $\varepsilon = 1,28; 1,55; 2; 3,2; 7$ i 120	12
2.3	Grafički prikazi ε - β distribucije raščlanjenosti ulaznih neizrazitih skupova (slika 2.2), definiranih funkcijama pripadnosti (2.20-21)	13
2.4	Dijagrami apsolutne normalizirane vrijednosti pozicije centara izlaznih neizrazitih skupova $ Y_{cj}(x_j) $, za ε - β distribuciju raščlanjenosti ulaznih neizrazitih skupova (slika 2.3).....	14
2.5	Princip rada konvencionalnog neizrazitog regulatora	19
2.6	Princip rada analitičkog neizrazitog regulatora	20
2.7	Grafički prikazi ε - β distribucije raščlanjenosti ulaznih neizrazitih skupova (slika 2.2), definiranih funkcijama pripadnosti (2.30-31) pri različitim vrijednostima β parametra	21
2.8	Apsolutne vrijednosti normaliziranih pozicija centara izlaznih neizrazitih skupova $ Y_{cj}(x_j) $, za ε - β distribuciju raščlanjenosti neizrazitih skupova (slika 2.3), pri različitim vrijednostima β i γ parametra	23
2.9	Prikaz karakterističnog područja djelovanja NAR -a, za različite vrijednosti parametra β , analitičkim pristupom (2.20-23 i 2.24) a), i poboljšanim suvremenim analitičkim pristupom (2.30-32) b)	24
2.10	Prikaz nelinearnih nivo upravljačkih krivulja $u_F = \Psi(e, de) = \text{const}$, za $\Delta u_F = 0,2$ i $\beta = 0$ te različitim vrijednostima slobodnog F i γ_1 parametra	28
2.11	Prikaz nelinearnih nivo upravljačkih krivulja $u_F = \Psi(e, de) = \text{const}$, za $\Delta u_F = 0,2$ i $\beta = 0,035$ te različitim vrijednostima slobodnog F i γ_1 parametra	29
2.12	Prikaz nelinearnih nivo upravljačkih krivulja $u_F = \Psi(e, de) = \text{const}$, za $\Delta u_F = 0,2$ i $\beta = 0,1$ te različitim vrijednostima slobodnog F i γ_1 parametra	30

Br. sl.	Naziv slike	Str.
2.13	Grafovi karakterističnih krivulja (2.57) a) i prirasta upravljačke varijable Δu_F u statičkoj radnoj točki $T(e_n, (u_F)_n)$, progresivne-a ($F=1,64 \beta=0$), linearne-b ($F=0,49 \beta=0.033$) i degresivne-c ($F=0,15 \beta=2,29$) karakteristične krivulje b) pri $U_m=15V$	33
2.14	Prikaz familije nelinearnih zavisnosti statičkog pojačanja $K_{Fe}(e)$ o pogrešci a), te prirasta statičkog Pojačanja ΔK_F u statičkoj radnoj točki $T(e_n, (u_F)_n)$ b), za različite karakteristične krivulje prikazane na (slici 2.13)	36
2.15	Grafički prikaz rada rekurzivnog algoritma (2.72) pri bijektivnom određivanju međusobne zavisnosti F^* i β^* parametra pri nelinearnoj funkciji $(u_F)_n = Y_e(e_n, F, \beta)...$	39
2.16	Blok dijagram algoritma programske realizacije pri određivanju općenito nelinearne bijekcijske funkcionalne zavisnosti između F i β parametra	41
2.17	Prikaz nelinearnih funkcija osjetljivosti upravljačke varijable o F i β parametru, a) $\Theta_F(e)$ i b) $\Theta_\beta(e)$, za karakteristične krivulje prikazane na (slici 2.13)	42
2.18	Struktura PNAR-a pri vođenju mobilnog robota unaprijed zadanom referentnom trajektorijom u prostoru unutarnjih upravljanih koordinata	44
3.1	Prikaz nelinearne zavisnosti $\eta(\beta)$, za slijedeće vrijednosti parametara $K_n=1 \beta_a=0.0105$ (a), $K_n=10 \beta_b=0.033$ (b) i $K_n=50 \beta_c=0,0165$ (c)	47
3.2	Prikaz nelinearne funkcijske zavisnosti $\beta(F)$, pri nultom stupnju neizrazitog djelovanja ($\eta=0$) za različite vrijednosti rastućeg parametra K_n	47
3.3	a) Prikaz karakterističnog neizrazitog prostora prve klase PNAR (3.2), karakterističnih krivulja u progresivnom modu rada b) $u_F = \psi(e^*, de)$; c) $u_F = \psi(e, de^*)$ i nivo upravljačkih krivulja d) $\Psi(e, de, F^*, \beta^*) = \text{const}$ u faznoj ravni stanja	48
3.4	a) Prikaz karakterističnog neizrazitog prostora druge klase PNAR (3.3), karakterističnih krivulja u degresivnom modu rada b) $u_F = \psi(e^*, de)$; c) $u_F = \psi(e, de^*)$ i nivo upravljačkih krivulja d) $\Psi(e, de, F^*, \beta^*) = \text{const}$ u faznoj ravni stanja	49
3.5	Blok dijagram algoritma programske podrške pri početnom podešavanju PNAR-a ...	50
3.6	a) Prikaz karakterističnog neizrazitog prostora ugođenog PNAR-a; karakterističnih krivulja b) $u_F = \psi(e^*, de)$; c) $u_F = \psi(e, de^*)$ i nivo upravljačkih krivulja d) $\Psi(e, de, F^*, \beta^*) = \text{const}$ u faznoj ravni pri $(u_F)_n=2,277 V$ i $K_{np}=10$ i $K_{nv}=6$	51
3.7	Prikaz nelinearnih nivo upravljačkih krivulja $\Psi(e, de, F^*, \beta^*) = \text{const}$ pri $(u_F)_n=2,277 V$ a) $K_{np}=10, K_{nv}=2$; b) $K_{np}=5 K_{nv}=12$	53

Br. sl.	Naziv slike	Str.
3.8	Slika 3.8 Rezultati simulacije praćenja referentne trajektorije mobilnog robota pri nominalnoj brzini 0,4 (m/s) vođenog početno podešenim PD-PNAR -om i klasičnim linearnim PD zakonom upravljanja	55
3.8a	Prikazi uvećanih detalja rezultata simulacije praćenja referentne trajektorije mobilnog robota prikazane slikom 3.8 u prostoru vanjskih koordinata	56
3.9	Dijagram pogreške položaja lijevog pogonskog kotača, prilikom praćenja referentne trajektorije (slika 3.8) sa početno podešenim PD-PNAR -om parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$ i $P=2,27$	57
3.10	Dijagram pogreške položaja desnog pogonskog kotača, prilikom praćenja referentne trajektorije (slika 3.8) sa početno podešenim PD-PNAR -om parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$	57
3.11	Dijagram pogreške brzine lijevog pogonskog kotača, prilikom praćenja referentne trajektorije sa (slika 3.8), sa početno podešenim PD-PNAR -om parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$	57
3.12	Dijagram pogreške brzine desnog pogonskog kotača, prilikom praćenja referentne trajektorije (slika 3.8) sa početno podešenim PD-PNAR -om parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$	58
3.13	Položaj centra izlaznog neizrazitog skupa pozicije Y_e početno podešenog PD-PNAR -a parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$, pri slijeđenju referentne trajektorije (slika 3.8)	58
3.14	Položaj centra izlaznog neizrazitog skupa brzine Y_{de} početno podešenog PD-PNAR -a parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$, pri slijeđenju referentne trajektorije (slika 3.8)	59
3.15	Dijagramski prikaz upravljačkih varijabli (u_r) istosmjernog servosustava lijevog i desnog pogonskog kotača pri slijeđenju referentne trajektorije (slika 3.8) s implementiranim početno podešenim PD-PNAR -om parametara ($K_{Fe}=12$; $K_{Fde}=5$)..	59
3.16	Prirast neizrazite upravljačke varijabli (Δu_r) lijevog i desnog pogonskog kotača pri slijeđenju referentne trajektorije (slika 3.8) s implementiranim početno podešenim PD-PNAR -om ($K_{Fe}=12$; $K_{Fde}=5$) u odnosu na linearni PD -zakon upravljanja	60

Br. sl.	Naziv slike	Str.
3.17	Promjena vrijednosti nelinearnog statičkog pojačanja $K_{Fe} \approx 12$ i $K_{Fde} \approx 5$ početno podešenog PD-PNAR -a ($K_{Fe}=12$; $K_{Fde}=5$) istosmjernih servosustava lijevog i desnog pogonskog kotača pri slijeđenju referentne trajektorije (slika 3.8)	60
3.18	Dijagramski prikaz promjene vrijednosti sistemskih polova λ_i ($i=1,..4$) uslijed neizrazitog djelovanja početno podešenog PD-PNAR -a ($K_{Fe} \approx 12$; $K_{Fde} \approx 5$) pri slijeđenju referentne trajektorije (slika 3.8)	61
3.19	Prikaz vođenja mobilnog robota PNAR -om u uvjetima zatvorene regulacijske petlje o položaju i brzini sa predupravljanjem pojačanja P u uvjetima otvorene regulacijske petlje	62
3.20	Dijagram pogreške položaja pogonskih kotača, prilikom vođenja mobilnog robota referentnom trajektorijom (slika 3.8), uz generiranje nemjerljivog poremećaja konstantnog iznosa (slika 3.19), te početnog poremećaja $\Delta q_l = -0,17$ i $\Delta q_d = 0,17$	62
3.21	Dijagram pogreške brzine pogonskih kotača, prilikom vođenja mobilnog robota referentnom trajektorijom (slika 3.8), uz generiranje nemjerljivog poremećaja konstantnog iznosa (slika 3.19), te početnog poremećaja $q_l = -0,17$ i $\Delta q_d = 0,17$	63
3.22	Dijagram izlazne pogreške položaja pogonskih kotača, prilikom vođenja mobilnog robota referentnom trajektorijom (slika 3.8), uz implementirani PD-PNAR sa dodatnim integracijskim djelovanjem na izlazu pojačanja $K_f=5$, ($M=1$, slika 2.17)...	63
3.23	Dijagram izlazne pogreške brzine pogonskih kotača, prilikom vođenja mobilnog robota referentnom trajektorijom (slika 3.8), uz implementirani PD-PNAR sa dodatnim integracijskim djelovanjem na izlazu pojačanja $K_f=5$, ($M=1$, slika 2.17)...	64
3.24	Dijagram neizrazite upravljačke varijable $u_f(n)$ servosustava pogonskih kotača pri vođenju mobilnog robota referentnom trajektorijom (slika 3.8) uz implementirani PD-PNAR (slika 2.17 $M=0$), te djelovanje nemjerljivog poremećaja konstantnog iznosa (slika 3.19) i početnog poremećaja	64
3.25	Dijagram neizrazite upravljačke varijable $u_f(n)$ servosustava pogonskih kotača pri vođenju mobilnog robota referentnom trajektorijom (slika 3.8), uz implementirani PD-PNAR s integracijskim djelovanjem na izlazu pojačanja $K_f=5$, ($M=1$, slika 2.17)	65

Br. sl.	Naziv slike	Str.
4.1	Općenita struktura samoorganiziranja PD-PNAR -a po pogrešci slijeđenja nominalne upravljačke varijable	67
4.2	a) Nominalna (-d) i ostvarena pozicija (-c) početno ugođenog PNAR -a ($K_{np}=10$, $K_{nv}=6$), b) nominalna (-d) i ostvarena brzina (-c) podešenog PNAR -a u prostoru unutarnjih upravljanih koordinata	71
4.3	a) Neizrazite vrijednosti pojačanja pozicije (K_{Fe} , V/rad) i brzine (K_{Fde} , Vs/rad) početno podešenog PNAR -a ($K_{np}=10$, $K_{nv}=6$); b) Polovi sustava u uvjetima zatvorenih regulacijskih petlji	72
4.4	Pogreška pozicije a), brzine b) na početku (-c) i na kraju procesa adaptacije nakon 60 iteracija (promjena referenci) (-d)	72
4.5	Položaj centra izlaznog neizrazitog skupa pogreške pozicije Y_e a), i pogreške brzine Y_{de} b) na početku (-c) i na kraju procesa adaptacije nakon 60 promjena referenci (-d)	73
4.6	a) Vrijednosti neizrazite upravljačke varijable $u_F(n)$ na početku (-d) i na kraju procesa adaptiranja (60 promjena referenci) (-c) i prikaz promjene upravljačke varijable $\Delta u_F(n)$ nakon procesa adaptiranja u odnosu na početno zgođeni PD -neizraziti regulator b)	73
4.7	Prikaz nivo upravljačkih krivulja $u_F=\text{const}$ u faznoj ravnini stanja početno ugođenog PD-PNAR -a, na početku a) i na kraju procesa adaptiranja nakon 60 iteracija b)	74
4.8	Prikaz postignute pozicije a) i brzine b) početno ugođenog PD-PNAR -a, ($K_{np}=10$, $K_{nv}=6$) prije početka (-d) i nakon završetka procesa adaptiranja (-c)	74
4.9	Promjene neizrazitih vrijednosti pojačanja pozicije (K_{Fe}) i brzine (K_{Fde}) a), te prikaz promjena karakterističnih vrijednosti sustava λ_i ($i=1,2,3,4$) u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini po završetku procesa adaptiranja b)	75
4.10	Prikaz vrijednosti ISE_e (3.18) pozicije po iteracijama (promjenama reference) pri procesu adaptiranja slobodnih parametara PD-PNAR -a	75

Br. sl.	Naziv slike	Str.
4.11	Prikaz ISE_{de} (3.18) brzine po iteracijama (promjenama reference) pri procesu adaptiranja slobodnih parametara PD-PNAR -a	76
4.12	Promjene vrijednosti $ISE_e=0,01$ kao kriterija zaustavljanja procesa adaptiranja za različite vrijednosti faktora obučavanja (a)- $A_{Fe}=0,16$; $A_{Fde}=0,14$; $A_{\beta e}=0,67$; $A_{\beta de}=0,97$; (b)- $A_{Fe}=0,044$; $A_{Fde}=0,045$; $A_{\beta e}=0,184$; $A_{\beta de}=0,31$; (c)- $A_{Fe}=0,022$; $A_{Fde}=0,03$; $A_{\beta e}=0,092$; $A_{\beta de}=0,21$; (d)- $A_{Fe}=0,014$; $A_{Fde}=0,02$; $A_{\beta e}=0,06$; $A_{\beta de}=0,14$	76
4.13	Promjena vrijednosti ISE_{de} po iteracijama (promjenama referenci) pri procesu adaptiranja za različite vrijednosti faktora obučavanja: (a)- $A_{Fe}=0,16$; $A_{Fde}=0,14$; $A_{\beta e}=0,67$; $A_{\beta de}=0,97$; (b)- $A_{Fe}=0,044$; $A_{Fde}=0,045$; $A_{\beta e}=0,184$; $A_{\beta de}=0,31$; (c)- $A_{Fe}=0,022$; $A_{Fde}=0,03$; $A_{\beta e}=0,092$; $A_{\beta de}=0,21$; (d)- $A_{Fe}=0,014$; $A_{Fde}=0,02$; $A_{\beta e}=0,06$; $A_{\beta de}=0,14$	77
4.14	Pogreška pozicije pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku a) i nakon procesa adaptiranja slobodnih parametara PD-PNAR -a b)	78
4.15	Pogreška brzine pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku a) i nakon procesa adaptiranja slobodnih parametara PD-PNAR -a b)	78
4.16	Položaji centara izlaznih neizrazitih skupova pogreške pozicije Y_e pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku a) i nakon procesa adaptiranja slobodnih parametara PD-PNAR -a b)	79
4.17	Položaji centara izlaznih neizrazitih skupova pogreške brzine Y_{de} pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku a) i nakon procesa adaptiranja slobodnih parametara PD-PNAR -a b)	79
4.18	Neizrazita upravljačka veličina $u_F(n)$ servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota referentnom putanjom slika 3.8) na početku a) i nakon procesa adaptiranja slobodnih parametara PD-PNAR -a b)	79

Br. sl.	Naziv slike	Str.
4.19	Promjena neizrazite upravljačke veličine $\Delta u_F(n)$ nakon procesa adaptiranja u odnosu na početno ugođeni PD-PNAR servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8)	80
4.20	Vrijednosti neizrazitih pojačanja pozicije K_{Fe} i brzine K_{Fde} početno ugođenog PD-PNAR -a servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8)	80
4.21	Vrijednosti neizrazitih pojačanja pozicije (K_{Fe}) nakon procesa adaptiranja slobodnih parametara PD-PNAR -a servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8)	81
4.22	Vrijednosti neizrazitih pojačanja brzine (K_{Fde}) nakon procesa adaptiranja slobodnih parametara PD-PNAR -a servosustava pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8)	81
4.23	Polovi dinamičkog sustava mobilnog robota s implementiranim početno ugođenim PD-PNAR -om u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini (slika 2.17, $M=0$) pri vođenju mobilnog robota referentnom putanjom (slika 3.8)	82
4.24	Polovi dinamičkog sustava nakon procesa adaptiranja slobodnih parametara PD-PNAR -a u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini (slika 2.17, $M=0$) pri vođenju mobilnog robota referentnom putanjom (slika 3.8)	82
4.25	Ostvarene trajektorije u prostoru unutarnjih upravljanih koordinata b), pri gibanja mobilnog robota zadanim referentnim putanjama u vanjskim koordinatama a)	83
4.26	Pogreške pozicije Δq a), b) i brzine $\Delta \dot{q}$ c), d) servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota različitim zadanim referentnim putanjama (a,b,c i d) sa slike 4.25a	83
4.27	Položaji centara izlaznih neizrazitih skupova pogreške pozicije Y_e a), b) i brzine Y_{de} c), d) servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota različitim zadanim referentnim putanjama (a,b,c i d) sa slike 4.25a	84

Br. sl.	Naziv slike	Str.
4.28	Upravljačka varijabla u_F , a), b) servosustava lijevog i desnog pogonskog kotača sa implementiranim PD-PNAR -om i klasičnim PD regulatorom, te promjene upravljačke varijable Δu_F c) i d) u odnosu na dinamički sustav s implementiranim klasičnim PD -regulatorom pri vođenju mobilnog robota različitim zadanim referentnim putanjama (a,b,c i d) sa slike 4.25a	84
4.29	Vrijednosti neizrazitog pojačanja pozicije (K_{Fe}) a), b) i brzine (K_{Fde}) c), d) servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota različitim zadanim referentnim putanjama (a,b,c i d), (slika 4.25a)	85
4.30	Promjena polova u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini, (slika 2.17, $M=0$) pri vođenju mobilnog robota sa PD-PNAR -om pri različitim zadanim referentnim putanjama a) (-a), b) (-b), c) (-c) i d) (-d), slika 4.25a	86
4.31	Prikaz gibanja norme trajektorije pogreške u n-dimenzijskom prostoru prije $\ \Delta x(t)\ $ i poslije procesa adaptiranja $\ \Delta x^*(t)\ $ a), te prikazivanje gibanja upravljačke varijable prije $u_r(t)$ i nakon procesa adaptiranja slobodnih parametara PD-PNAR -a b)	89
4.32	Struktura modela signala razlike pri postupku adaptiranja slobodnih parametara PD-PNAR -a	90
5.1	Struktura dinamičkog modela odstupanja od željene referentne trajektorije sa implementiranim NAR pri djelovanju početnog poremećaja	95
5.2	Grafički prikaz statičke nelinearnosti tipa Amplitudnog Zasićenja (AZ) a), prikazanih faznom ravninom stanja pogreške pozicije i brzine pri nelinearnim funkcijama ograničenja $\pm \Psi_{max}(e, \Delta e) = (\Delta u_r)_{max} $ na upravljačku varijablu u_r b)	96
5.3	a) Ostvarene trajektorije u prostoru unutarnjih koordinata sa linearnim PD -regulatorom (-c), nelinearnim PD-PNAR -om sa (-a) i bez statičke nelinearnosti (-b) tipa AZ (Slika 5.2); b) Prikaz promjene upravljačke varijable sa implementiranim linearnim PD -regulatorom pri različitim vrijednostima poremećaja tipa početnih uvjeta $\Delta q=-0,15$ (-a), $\Delta q=-0,35$ (-b) i $\Delta q=-0,55$ (-c)	97

Br. sl.	Naziv slike	Str.
5.4	Ostvarene trajektorije brzine u prostoru unutarnjih upravljanih koordinata sustava sa linearnim PD -regulatorom a) i nelinearnim PD-PNAR -om b), sa (-d) i bez statičke nelinearnosti (-e), AZ (slika 5.2) pri različitim vrijednostima početnih uvjeta (slika 5.3)	97
5.5	Promjena neizrazite upravljačke varijable dinamičkog sustava (slika 5.1) sa implementiranim nelinearnim PD-PNAR -om sa b) i bez statičke nelinearnosti a), AZ upravljačke varijable (slika 5.2) pri različitim vrijednostima početnih uvjeta (slika 5.3)	98
5.6	Vrijednosti neizrazitih pojačanja pozicije K_{Fe} a) i brzine K_{Fde} b), sa (-d) i bez statičke nelinearnosti (-e), AZ upravljačke varijable (slika 5.2), pri različitim vrijednostima poremećaja tipa početnih uvjeta $\Delta q = -0,15$ (a), $\Delta q = -0,35$ (b) i $\Delta q = -0,55$ (c) (slika 5.3)	98
5.7	Grafički prikazi granične stabilnosti a) i nestabilnosti b) pri odabranim većim vrijednostima poremećaja tipa početnih uvjeta	99
5.8	Struktura adaptiranja slobodnih parametara PD-PNAR -a pri procijenjenoj maksimalnoj vrijednosti vanjskog poremećaja tipa početnih uvjeta Δq_{max}	100
5.9	Grafički prikaz vrijednosti ISE pozicije (4.18) po iteracijama (promjenama reference) pri procesu adaptiranja slobodnih parametara PD-PNAR -a	101
5.10	Grafički prikaz ostvarene trajektorije poremećaja a) i pogreške b) na početku (-e) i na završetku adaptiranja nakon 97 promjena reference sa (-c) i bez (-d) statičke nelinearnosti AZ neizrazite upravljačke varijable PD-PNAR -a	102
5.11	Grafički prikaz neizrazite upravljačke varijable na početku (-d) i na završetku adaptiranja nakon 97 iteracija (-c), sa a) i bez b) statičke nelinearnosti AZ upravljačke varijable	102
5.12	Model adaptacije slobodnih parametara PI-PNAR -a pri vrijednosti integracijskog pojačanja $K_I = 1$ i maksimalnoj procijenjenoj vrijednosti vanjskog konstantnog poremećaja $(\Delta u_p)_{max}$	109

Br. sl.	Naziv slike	Str.
5.13	Grafički prikaz vrijednosti ISE pozicije (3.18) po iteracijama (promjenama reference) pri procesu adaptacije slobodnih parametara PI-PNAR -a	110
5.14	Grafički prikaz ostvarene trajektorije a) i upravljačke varijable na ulazu objekta regulacije b), uslijed djelovanja konstantnog nemjerljivog vanjskog poremećaja od strane implementiranog PD-PNAR -a (-d), i implementiranog PI-PNAR -a na početku (-e) i na kraju procesa adaptacije (-c)	111
5.15	Struktura modela odstupanja od željene referentne trajektorije pri djelovanju konstantnih nemjerljivih vanjskih poremećaja $(\Delta u_p)_{\max}$ uz mogućnost podešavanja integralnog pojačanja implementiranog PID-PNAR -a	112
5.16	Struktura modela odstupanja od željene referentne trajektorije pri djelovanju konstantnih nemjerljivih vanjskih poremećaja $(\Delta u_p)_{\max}$ uz mogućnost podešavanja integralnog pojačanja paralelno dodanog klasičnog integralnog člana PD-PNAR -u parametara (5.17)	113
5.17	Dijagrami ostvarene trajektorije a) i upravljačke varijable b), uslijed djelovanja vanjskog konstantnog nemjerljivog poremećaja na početku podešavanja sa implementiranim PD-PNAR -om (-d), i na završetku podešavanja integralnog pojačanja uz paralelno uvedeni integracijski signal od strane klasičnog integracijskog člana (-e), (slika 5.16) i izlaza PD-PNAR -a (-c), (slika 5.15)	116
5.18	Struktura samoorganiziranja s paralelno uvedenim klasičnim integralnim članom, izlazu PD-PNAR -a	117
5.19	Struktura samoorganiziranja PD-PNAR -a s paralelno uvedenim klasičnim integralnim članom	118
6.1	Struktura mikroprocesorskog vođenja mobilnog robota sa implementiranim PNAR -om kao nelinearnim algoritmom upravljanja u prostoru unutarnjih upravljanih koordinata	121
6.2	Formiranje memorijske kvadratne matrice (tablice) $\dim(2^{\hat{n}+1} + 1)$ neizrazite upravljačke varijable	122

Br. sl.	Naziv slike	Str.
6.3	a) Aktiviranje memorijskih lokacija ulaznim varijablama (e^*, de^*) te prikaz polaganja aproksimacijske upravljačke površine nad aktiviranim memorijskim lokacijama upravljačke kartice b)	124
6.4	Prikaz upravljačke strukture pri ON -line vođenju mobilnog robota u realnom vremenu sa implementiranom MKNUD a), i implementiranim nelinearnim PI -regulatorom b)	125
6.5	Dijagram izlazne pogreške pozicije servosustava lijevog i desnog pogonskog kotača, pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8) sa implementiranom MKNUD -a (slika 6.4a)	126
6.6	Dijagram izlazne pogreške brzine servosustava lijevog i desnog pogonskog kotača, pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8) sa implementiranom MKNUD -a (slika 6.4a)	126
6.7	Dijagramski prikaz neizrazite upravljačke varijable (6.10) istosmjernih servosustava lijevog i desnog pogonskog kotača pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8), sa MKNUD -a (slika 6.4a)	127
6.8	Dijagramski prikaz promjene vrijednosti dinamičkog pojačanja pozicije (6.9), pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8) i sa implementiranom MKNUD -a (slika 6.4a)	127
6.9	Dijagramski prikaz promjene vrijednosti dinamičkog pojačanja brzine (6.9), pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8) i sa implementiranom MKNUD -a (slika 6.4a)	127
6.10	Dijagramski prikaz upravljačke varijable nelinearnog P djelovanja (6.11) implementirane upravljačke strukture (slika 6.4b) pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8)	128
6.11	Dijagramski prikaz upravljačke varijable nelinearnog I djelovanja (6.12) implementirane upravljačke strukture (slika 6.4b) pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom sa (slika 3.8)	129

Br. sl.	Naziv slike	Str.
6.12	Dijagramski prikaz upravljačke varijable nelinearnog I djelovanja (6.12) implementirane upravljačke strukture (slika 6.4b) pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom sa (slika 3.8)	129
6.13	Dijagramski prikaz ukupne nelinearne upravljačke varijable (6.13) implementirane upravljačke strukture (slika 6.4b) pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8)	130
6.14	Dijagram izlazne pogreške pozicije pogonskih kotača pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8), i sa implementiranom upravljačkom strukturom (slika 6.4b)	130
6.15	Dijagram izlazne pogreške brzine pogonskih kotača pri ON -line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8), s implementiranom upravljačkom strukturom (slika 6.4b)	130
6.16	Dijagramski prikaz stacionarnog ergodičnog mjernog »bijelog šuma« čije amplitude posjeduju Gausovu razdiobu sa srednjom vrijednosti $\bar{w} = 0$ i varijancom $V_w = I$	133
6.17	Prikaz upravljačke strukture sa implementiranom MKNUD -a i nelinearnim PI -regulatorom sa Kalman-Bucy filterom za procjenu vektora stanja u realnim uvjetima djelovanja smetnji pri ON -line vođenju mobilnog robota u realnom vremenu	135
6.18	Dijagramski prikaz prijelazne pojave komponenata H_{ij} simetrične matrice varijance H (t) Kalman-Bucy filtera dobivene rješavanjem nelinearne diferencijalne matrične Rikatijske jednačbe pri različitim početnim vrijednostima matrice H_{0i} $i=1..3$ (6.42)	137
6.19	Stohastička realizacija mjernog signala pozicije lijevog i desnog pogonskog kotača pri ON -line vođenju mobilnog robota zadanom referentnom trajektorijom (slika 3.8) a implementiranom upravljačkom strukturom prikazanom na (slici 6.17) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma parametara $\bar{w}_i = 0$ i $V_{w_i} = 0,1$	138

Br. sl.	Naziv slike	Str.
6.20	Pogreška pozicije a) i brzine b) pri vođenju mobilnog robota trajektorijom, (slika 6.19) s Kalmanovim pojačanjima (6.43) upravljačke strukture (slika 6.17), u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	139
6.21	Promjena upravljačke varijable pri vođenju mobilnog robota trajektorijom, (slika 6.19) s Kalmanovim pojačanjima (6.43) upravljačke strukture (slika 6.17) u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	139
6.22	Pogreška pozicije a) i brzine b) pri vođenju mobilnog robota trajektorijom, (slika 6.19) s Kalmanovim pojačanjima (6.47) upravljačke strukture (slika 6.17), u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	140
6.23	Promjena upravljačke varijable pri vođenju mobilnog robota trajektorijom, (slika 6.19) s Kalmanovim pojačanjima (6.47) upravljačke strukture (slika 6.17) u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	140
6.24	Dijagrami pogreške estimacije izlazne varijable pozicije a) i stanja brzine b), pri vođenju mobilnog robota trajektorijom (slika 6.19) i implementiranim Kalmanovim pojačanjima (6.43) dane upravljačke strukture (slika 6.17) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	141
6.25	Dijagrami pogreške estimacije izlazne varijable pozicije a) i stanja brzine b), pri vođenju mobilnog robota trajektorijom (slika 6.19) sa implementiranim Kalmanovim pojačanjima (6.47) dane upravljačke strukture (slika 6.17) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	142
6.26	Dijagrami iščezavanja pogreške procijene izlazne varijable pozicije servosustava lijevog a) i desnog b) pogonskog kotača pri vođenju mobilnog robota trajektorijom (slika 3.8), uz početne uvijete (6.48) upravljačke strukture (slika 6.27a), i Kalmanova pojačanja (6.43) $\Rightarrow (\cdots)$; (6.47) $\Rightarrow (- - -)$ i vremenski promjenjivih neizrazitih pojačanja $K_F(e,t) \Rightarrow (-)$ upravljačke strukture na (slici 6.27b)	143

Br. sl.	Naziv slike	Str.
6.27	Upravljačka struktura s implementiranom MKNUD i nelinearnim PI -regulatorom sa Kalman-Bucy filterom kao optimalnim observerom ustaljenog stanja sa stacionarnim vrijednostima \mathbf{K}_F a), i nelinearnim vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ pri ON -line vođenju mobilnog robota u uvjetima postojanja vanjske i interne smetnje	144
6.28	Dijagrami pogreške pozicije a) i brzine b) pri vođenju mobilnog robota trajektorijom (slika 3.8) s implementiranim nelinearnim vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ upravljačke strukture (slika 6.27b) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	147
6.29	Dijagram upravljačke varijable pri vođenju mobilnog robota trajektorijom, (Slika 6.19) s implementiranim nelinearnim vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ upravljačke strukture (slika 6.27b) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$) ..	147
6.30	Dijagrami pogreške estimacije izlazne varijable pozicije a) i stanja brzine b), pri vođenju mobilnog robota trajektorijom (slika 3.8) s vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ strukture (slika 6.27b), u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	148
6.31	Dijagrami neizrazitih vrijednosti Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ (6.49) upravljačke strukture (slika 6.27b) pri vođenju mobilnog robota trajektorijom (slika 6.19), u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	149
6.32	Promjena parametra β_{ij} raščlanjenosti i -tog stanja neizrazitih skupova j -te ulazne varijable (6.54), s neizrazitim vrijednostima Kalmanovih pojačanja (6.49) upravljačke strukture (slika 6.27b) pri vođenju mobilnog robota trajektorijom, (slika 3.8) u uvjetima prisutne mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)	150
6.33	Dijagram nestacionarnog mjernog »bijelog šuma« nulte srednje vrijednosti (6.60).	151

Br. sl.	Naziv slike	Str.
6.34	Pogreška estimacije izlazne varijable pozicije a) i stanja brzine b) pri vođenju mobilnog robota trajektorijom (slika 6.19) sa vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $K_F(\Delta y, t)$ upravljačke strukture (slika 6.27b) u uvjetima postojanja nestacionarne mjerne smetnje (izraz 6.60 i slika 6.33)	152
6.35	Promjena varijable β_{ij} raščlanjenosti i-tog stanja neizrazitih skupova j -te ulazne varijable (6.54), sa neizrazitim vrijednostima Kalmanovih pojačanja (6.49), strukture (slika 6.27b) pri vođenju mobilnog robota trajektorijom (slika 6.19) pri postojanju nestacionarne mjerne smetnje (izraz 6.60 i slika 6.33)	153
6.36	Promjena neizrazitih vrijednosti Kalmanovih pojačanja $K_F(\Delta y, t)$ (6.49) upravljačke strukture (slika 6.27b) pri vođenju mobilnog robota trajektorijom (slika 6.19), u uvjetima postojanja nestacionarne mjerne smetnje (izraz 6.60 i slika 6.33)	154

POPIS TABLICA

Br. tb.	Naziv tablice	Str.
2.1	Osnovni parametri ulaznih neizrazitih skupova suvremenog neizrazitog regulatora	22
2.2	Osnovni parametri izlaznih neizrazitih skupova suvremenog neizrazitog regulatora	38
3.1	Parametri istosmjernih električnih motora za mobilni robot sa dva rotacijska stupnja slobode gibanja	54
4.1	Osnovni parametri adaptacije početno ugođenog PD-PNAR -a	71
4.2	Vrijednosti ISE , pri vođenju mobilnog robota različitim referentnim trajektorijama (slika 4.25) sa implementiranim zakonima upravljanja (4.28-29)	86
5.1	Koeficijenti brzine učenja nelinearnog algoritma adaptiranja početno ugođenog PD-PNAR -a	101
5.2	Koeficijenti brzine učenja nelinearnog algoritma adaptiranja početno ugođenog PI-PNAR -a	110
6.1	Osnovni parametri neizrazitog pojačanja $K_F(\Delta y, t)$	146

POPIS AKRONIMA (KRATICA)

Br. ak.	Akronim	Značenje akronima
1.	NR	Neizraziti R egulator
2.	NS	Neizraziti S kup
3.	NAR	Neizraziti A nalitički R egulator
4.	AMR	Autonomni M obilni R obot
5.	MKNUD	M emorijska K artica Neizrazitog U pravljačkog D ijelovanja
6.	D/N	D ecimalno - Neizrazita pretvorba
7.	N/D	Neizrazito - D ecimalna pretvorba
8.	PNAR	P oboljšani Neizraziti A nalitički R egulator
9.	P	P roporcionalno djelovanje
10.	PD	P roporcionalno – D erivacijsko djelovanje
11.	PI	P roporcionalno – I ntegralno djelovanje
12.	PID	P roporcionalno – I ntegralno – D erivacijsko djelovanje
13.	FLC	eng. F uzzy L ogic C ontrol (neizraziti regulator)
14.	SISO	eng. S ingle I ntput – S ingle O utput (jedan ulaz – jedan izlaz)
15.	MISO	eng. M ulti I ntput – S ingle O utput (više ulaza – jedan izlaz)
16.	MIMO	eng. M ulti I ntput – M ulti O utput (više ulaza – više izlaza)
17.	COG	eng. C enter O f G ravity method (metoda težišta)
18.	COA	eng. C enter O f A rea method (metoda središta površine)
19.	OR	O bjekt R egulacije
20.	MATLAB	MAT rični LAB oratorij
21.	ISE	Eng. I ntegral S quare E rror
22.	A/D	A nalogno – D igitalna pretvorba signala
23.	D/A	D igitalno – A nalogna pretvorba signala

Br. ak.	Akronim	Značenje akronima
24.	AZ	Amplitudno Z asićenje
25.	KBF	K alman B usijev (eng. B ucy) F ilter
26.	UNM	Umjetne Neuronske M reže
27.	GA	G enetski A lgoritam

1. UVOD

1.1 Povijesni osvrt razvoja konvencionalne neizrazite logike

U prvoj polovici 19 stoljeća kao temeljna disciplina suvremene matematike cvjetala je klasična teorija skupova koju je uveo njemački matematičar G. Cantor. Poznati njemački matematičar Hilbert govori slijedeće o teoriji skupova: »Cantorova teorija skupova čudotvorni je plod matematičkog duha i jedno od najvećih ostvarenja ljudskog stvaralaštva. Iz raja, kojeg nam je Cantor podario, neka nas nitko ne potjera.« Klasična teorija skupova strogo je definirala pojmove skupa i pripadnost skupu, koji su danas poznati kao »obični ili oštri, tvrdi skupovi« (eng. *crisp sets*). Nasuprot takvoj definiciji pripadnosti skupu u smislu da je misaoni pojam ili određeni predmet član ili ne određenog skupa, poljski matematičar Lukasiewicz kao i njegov istomišljenik francuski matematičar Boral idu korak dalje i uvode polovičnu pripadnost skupu, utirući tako temelje za rađanje nove ideje o »mekoj« ili »neizrazitoj« pripadnosti skupu koji se koriste pri kvalitativnom opisu predmeta ili misaonog pojma, a koju 1962. godine spominje američki matematičar azerbejdžanskog porijekla, profesor sa Sveučilišta u Berkeleyu (SAD) Lotfi A. Zadeh [1]. On 1965 godine uvodi i definira osnovne pojmove neizrazite logike kao što su neizraziti skup (eng. *fuzzy set*) i funkcija pripadnosti neizrazitom skupu (eng. *membership function*) [2], te se stoga smatra začetnikom neizrazite logike. Početkom sedamdesetih godina inspiriran radovima L. A. Zadeha [3,4], teoriju neizrazitih skupova u tehniku upravljanja uvodi profesor Ebrahim H. Mamdani iz londonskog Queen Mary koledža. Nemogućnost primjene standardnih algoritama upravljanja te bezuspješno projektiranje adaptivnog regulatora laboratorijskog modela parnog stroja od strane studenta Seto Asilliana [5,6], navela je Mamdanija da se iskoristi znanje operatera i projektira regulator koji bi to znanje interpretirao u obliku neizrazitih pravila regulacije [7]. To je bila prva eksperimentalna primjena neizrazite logike u upravljanju, da bi nakon višegodišnje eksperimentalne primjene neizrazitog upravljanja [8] 1980. godine bio realiziran prvi industrijski regulator u Danskoj [9]. Dakle teorija neizrazite logike punu afirmaciju doživljava svojom primenom kod realnih sustava koji se teško modeliraju i posjeduju izražene nelinearnosti. Stoga se s pravom kaže da su klasični skupovi zapravo samo rubni slučajevi neizrazitih skupova [10]. Iako prvi prijedlozi primjene neizrazite logike dolaze sa zapada [11] progresivna implementacija neizrazitih algoritama upravljanja, odnosno njihova prava komercijalizacija, uslijedila je u drugoj polovici osamdesetih godina

prošlog stoljeća u japanskoj industriji. U japanskom gradu Sendai od 1987. godine radi podzemna željeznica vođena načelom fuzzy (neizrazite) logike. Japanska industrija koristi neizrazitu upravljačku logiku pri upravljanju dizalima čime se znatno skraćuje vrijeme čekanja. Implementacija neizrazitih upravljačkih algoritama našla je svoju primjenu kod perilica rublja kompanije Matshushita, Sony-jevih televizora i u klimatizacijskoj tehnici gdje je neizraziti regulator temperature pokazao daleko bolje karakteristike u usporedbi s običnim PID-regulatorom, a ušteda energije je pritom i do 25%. Vidljivi su znatniji pomaci i u smjeru računalne tehnike (neuroračunarstva), gdje se sve više koriste komponente fuzzy-logike. Prikaz razvoja konvencionalnog pristupa neizrazitoj regulaciji može se naći u [12,13]. U prvoj polovici devedesetih godina prošlog stoljeća upotreba neizrazite logike u Japanu, proširila se na područje procesne i automobilske industrije, ekologije te području robotskih i transportnih sustava. Uvlačeći se u sve pore ljudskog djelovanja neizrazita logika svoju primjenu nalazi i u području zabavne elektronike, multimedije i virtualne realnosti, zatim ekonomije pa čak turizma i ugostiteljstva. Sa primjenom neizrazitih upravljačkih sustava počela je aktivnija i nakladnička djelatnost [14,15]. Na području teorije neizrazitih skupova, 1978. godine počeo je izlaziti časopis »Fuzzy Sets and Systems« izdavačke kuće North Holland, koji je danas jedan od vodećih na tom području. Godine 1985. održan je prvi kongres IFSA (eng. *International Fuzzy Systems Association*), međunarodnog udruženja za neizrazite sustave, tako da se krajem devedesetih godina opažaju vidljivi pomaci u tom pogledu i u Europi i SAD-u gdje se osnivaju nacionalna udruženja koja općenito propagiraju ideju neizrazitog upravljanja u svim područjima ljudskog djelovanja, da bi početkom 21 stoljeća se razvijali različiti pristupi u području neizrazite upravljačke tehnike od kojih zasigurno važno mjesto zauzima suvremeni analitički pristup.

1.2 Suvremeni analitički pristup u razvoju neizrazite logike

Općenito realni sustavi, kakvi se danas koriste u procesnoj industriji posjeduju izražene nelinearnosti sa velikim granicama i brzinama promjene parametara sustava. Modeliranje takvih sustava je vrlo otežano te se stoga dobivaju modeli složene strukture koji su posve neprikladni za projektiranje regulatora konvencionalnim putem. U takvim slučajevima i slučajevima kada je realni model sustava nepoznat vrši se identifikacija nepoznatog sustava formiranjem neizrazitih pravila regulacije [16,17]. Postoji čitav niz metoda identifikacije od kojih su najpoznatije tehnike klaster analize [18] i najmanjih kvadrata odstupanja [19]. Danas se kod nelinearnih sustava sa promjenjivim parametrima uspješno koriste različite metode adaptivnog upravljanja [20], kao što

su neposredno adaptivno upravljanje [21], adaptivno upravljanje sa referentnim modelom [22] i neizrazitim referentnim modelom [23] i dr. O adaptivnim neizrazitim slijednim sustavima raspravljaju Pacini i Kosko [24], dok općenito o neizrazitim adaptivnim klasifikacijskim sustavima raspravljaju Nozaki, Ishibuchi i Tanaka [25]. Razvojem neizrazite upravljačke tehnike, postupci stečeni višegodišnjim iskustvom operatera nastoje se općenito pretvoriti pomoću neizrazitih pravila regulacije AKO-ONDA u algoritam pogodan za mikroprocesorsko upravljanje [26,27,28]. U slučajevima kada operater sustav vodi po »osjećaju« i nije u stanju svoje postupke izraziti u obliku pravila po kojima vodi sustav, onda se pomoću neizrazitih pravila regulacije, vrši identifikacija njegovih postupaka [29]. Praktična realizacija adaptivnih metoda kod izrazito nelinearnih složenih sustava koji se teško modeliraju i imaju veći broj promjenjivih parametara prvenstveno je ograničena složenošću korištenog matematičkog aparata i zahtjevanog većeg broja iteracija. Općenito primjena neizrazite upravljačke tehnike sa većim brojem ulaznih i/ili izlaznih varijabli ograničena je time što broj neizrazitih pravila regulacije, potrebnih za formiranje baze neizrazitog djelovanja raste eksponencijalno s porastom broja varijabli [15]. Stoga je sa stajališta vođenja sustava u realnom vremenu njihova praktična primjena bez dodatnih pojednostavljenja strogo ograničena na svega dvije do tri ulazne varijable. Zato krajem 20. i početkom 21. stoljeća, nasuprot konvencionalnom pristupu redoviti profesor Fakulteta strojarstva i brodogradnje u Zagrebu, Branko Novaković s novim adaptivnim oblicima neizrazitih skupova [30], uvodi novi suvremeni analitički pristup neizrazitoj regulaciji [31,32,85]. Tim novim pristupom uvodi se analitička funkcija za preslikavanje ulazne varijable na poziciju centara izlaznih neizrazitih skupova i time se u procesu inferencije direktno izbjegava formiranje baze neizrazitih pravila regulacije, a samim tim i eksponencijalni porast broja neizrazitih pravila regulacije s brojem ulaznih varijabli. Time je znatno povećana brzina projektiranja i rada **Neizrazitog Regulatora (NR)**, što omogućuje njegovu primjenu u praksi. **Neizraziti Analitički Regulator (NAR)**, svoju primjenu prvenstveno pronalazi u slijednoj regulaciji pri vođenju nepokretnih i pokretnih robotskih sustava [32, 33], te regulacijskim krugovima alatnih strojeva i fleksibilnih proizvodnih sustava sa velikim brojem ulaznih varijabli. Nakon toga uslijedi niz radova iz tog područja [34,35,86], koji ukazuju na dobre strane novog suvremenog analitičkog pristupa neizrazitoj regulaciji.

1.3 Definiranje problema suvremenog analitičkog pristupa neizrazite regulacije

Inspirirano radovima [36,37], predložena je konstrukcija neholonomnog **Autonomnog Mobilnog Robot-skog (AMR)** sustava [38] i projektiran je nelinearni upravljački sustav za njegovo vođenje u prostoru vanjskih upravljanih koordinata [39]. U slijedećem koraku implementirani klasični PD-regulator zamjenjuje se s konvencionalnim neizrazitim regulatorom [40] i prikazuju usporedni rezultati s projektiranim suvremenim neizrazitim analitičkim regulatorom [41], pri vođenju **AMR** po unaprijed definiranoj referentnoj putanji u prostoru vanjskih upravljanih koordinata [42]. U tim radovima ukazuje se na prednost suvremenog analitičkog pristupa, nad konvencionalnim pristupom neizrazitoj regulaciji koja se ogleda prvenstveno u brzini rada, što **NAR** približava djelovanju u realnom vremenu. U općem slučaju, prilikom projektiranja **NAR**-a, za danu klasu tehničkog problema određenog objektom regulacije potrebno je odrediti aktivacijsku funkciju, oblik analitičke funkcije za preslikavanje ulaznih varijabli na pozicije centara izlaznih neizrazitih skupova i slobodne parametre analitičkog regulatora. Da bi se pronašle najprikladnije vrijednosti tih parametara [40], potreban je dugotrajan i mukotrpan proces interakcijskog rada sa elektroničkim računalom. Stoga je glavna motivacija ove doktorske disertacije povećanje brzine projektiranja, razvijanjem postupaka »učenja« **NAR**, sa zadatkom samoorganiziranja njegovih parametara u otvorenom modu rada. Kad se radi o **NAR**-u, u tom pravcu postoji relativno malo radova. Iako se brzina rada **NAR**-a, naglašava kao glavna prednost ispred konvencionalnog pristupa neizrazitoj regulaciji, tek njegova modifikacija, zajedno sa uvođenjem **Memorijske Kartice Neizrazitog Upravljačkog Djelovanja (MKNUĐ)**, a predložene u ovoj doktorskoj disertaciji omogućuje njegovu primjenu u praksi.

1.4 Razrada postavljenog problema po poglavljima

Ova doktorska disertacija podijeljena je na osam poglavlja. Nakon danog uvoda u prvom poglavlju dane su definicije i međusobne zavisnosti osnovnih pojmova suvremenog analitičkog pristupa neizrazitoj regulaciji. Iako su od konvencionalnog pristupa preuzeti gotovo svi osnovni pojmovi koji sudjeluju u formiranju strukture **NR** [43] oni se ovdje drugačije interpretiraju. U procesu **Decimalno-Neizrazite (D/N)** pretvorbe svaki ulazni neizraziti skup za razliku od konvencionalnog pristupa [44,45] definira se nad čitavim područjem razmatranja ulazne varijable [30]. Adaptacija ulaznih neizrazitih skupova, slično kao i prije [30,46] daje se u analitičkom obliku nove predložene funkcije pripadnosti, s kojom se poboljšavaju dosadašnja svojstva **NAR**-a. U procesu inferencije kod konvencionalnog pristupa [49], primjenjuju se metode određivanja neizrazitih pravila regulacije [47,48], potrebne za formiranje baze neizrazitih pravila regulacije. Kod suvremenog analitičkog pristupa u procesu inferencije ti postupci zamijenjeni su određivanjem funkcije u analitičkom obliku za preslikavanje ulaznih neizrazitih skupova na pozicije centara izlaznih neizrazitih skupova. Na taj način izbjegava se eksponencijalni porast neizrazitih pravila regulacije s brojem ulaznih varijabli [15]. Kao i kod konvencionalnog pristupa [50] i ovdje postoji mehanizam **(N/D)** pretvorbe koji se daje na uvid, kao i analiza pojedinih parametara u faznoj ravnini stanja, uz detaljno obrazloženje stupnja neizrazitog djelovanja **NAR**-a kao novo uvedenog pojma.

U trećem poglavlju predlaže se postupak početnog podešavanja (ugađanja) **Poboljšanog Neizrazitog Analitičkog Regulatora (PNAR-a)** kao nelinearnog **PD**-regulatora, pri čemu se slobodni parametri F i β dovode u međusobnu zavisnost preko neizrazitog stupnja djelovanja η . Utjecaj izbora slobodnih parametara na osnovni progresivni i regresivni mod rada **PNAR**-a, pokazuje se preko fazne ravnine stanja. **PNAR** je početno podešen, kad je u stanju minimalne pobuđenosti, odnosno kad posjeduje nulti stupanj neizrazitog djelovanja. U svom radu on se je tada po dinamičkim karakteristikama najviše približio konvencionalnom **PD**-regulatoru. Na kraju poglavlja dani su rezultati početnog ugađanja **PNAR**-a, u vidu dijagrama simulacije vođenja mobilnog robota odabranom složenom nominalnom putanjom u prostoru unutarnjih koordinata.

Konvencionalnim pristupom neizrazitoj regulaciji podešavanje parametara **NR** je moguće u **OFF** [51,52,53] i **ON-line** [54,55,56] modu rada. Najčešće korištena metoda u **OFF-line** modu rada je gradijentna metoda kojom se npr. u [51] podešavaju parametri središta i širine trokutastih funkcija pripadnosti, a Hook-Jeeves metodom [52] se ti isti parametri određuju kod Gausovih (zvonolikih) funkcija pripadnosti definirajući tako neizraziti algoritam upravljanja koji

emulira PD-regulator, dok se formiranjem neizrazitih pravila regulacije tipa Takagi-Sugeno [53] podešavaju samo izlazni singletoni. Jedna od rijetkih **ON**-line metoda podešavanja parametara koja ima svoju potvrdu u praksi je ona u [55], koja je ispitana na neizrazitom regulatoru koji upravlja računalnim numeričkim strojem za obradu metala. Nedostatak te kao i ostalih metoda su koeficijenti obučavanja koji se određuju empirijski i imaju značajan utjecaj na stabilnost sustava. Kod suvremenog analitičkog pristupa neizrazitoj regulaciji iz tog područja postoje jedino radovi vezani za **ON**-line adaptaciju parametara [32,33]. Zato se u četvrtom poglavlju ove doktorske disertacije predlaže u **OFF**-line modu rada nelinearni algoritam samoorganiziranja parametara **PNAR**-a modificiranom gradijentnom metodom. Koeficijenti obučavanja određuju se iskustveno i ovisno o njihovom odabiru ovisi brzina konvergencije i stabilnost algoritma samoorganiziranja. Pokazan je utjecaj izbora koeficijenata učenja na brzinu konvergencije algoritma samoorganiziranja. Zbog boljeg uvida u nelinearno djelovanje **PNAR**-a, po završetku samoorganiziranja dana je usporedba sa klasičnim regulatorom simulacijom vođenja mobilnog robota nominalnom putanjom složenijeg oblika u prostoru unutarnjih upravljanih koordinata, a na kraju poglavlja dani su uvjeti koje koeficijenti učenja trebaju ispunjavati da bi predloženi algoritam samoorganiziranja bio stabilan.

U petom poglavlju uspoređuje se rad **PNAR**-a kao nelinearnog diskretnog **PD**, **PI** i **PID** regulatora sa klasičnim regulatorima toga tipa [57,58,59,87]. U slučaju poremećaja tipa početnih uvjeta kod **PD-PNAR**-a, odnosno nemjerljivih vanjskih konstantnih poremećaja kod **PI-PNAR**-a, predlaže se nelinearni algoritam samoorganiziranja njihovih parametara. Osim ispitivanja stabilnosti algoritma samoorganiziranja i postavljanja ograničenja koeficijenata učenja dana su i ograničenja koje je potrebno ispuniti da bi se osigurala stabilnost algoritma regulacije. Motiviran radovima [60,61,62] pokazana je realizacija nelinearnog **PID-PNAR**-a paralelnim dodavanjem klasičnog integracijskog člana izlazu **PD-PNAR**-a i izlazu objekta regulacije. Za oba slučaja predložen je i algoritam za podešavanje integralnog pojačanja.

MKNUD je predložena u šestom poglavlju. Amplitudnom diskretizacijom neizrazitog algoritma upravljanja u analitičkom obliku je omogućeno vođenje mobilnog robota u realnom vremenu i prikazani su simulacijski rezultati. Pokazano je poboljšanje uvođenjem izrazito nelinearnog **PI**-regulatora paralelno postojećoj **MKNUD**-a. Uvođenje **MKNUD**-a ima veliku ulogu u suvremenom analitičkom pristupu neizrazitoj regulaciji. Ona predstavlja osnovu za primjenu sofisticiranijih algoritama upravljanja kao što su neuronske mreže [63,64]. Primjena neizrazitog zakona upravljanja moguća je u kombinaciji sa genetskim algoritmima [65] i neuronskim mrežama, kao što je neuro-fazi regulator [66] tvoreći tako hibridne zakone upravljanja. Neizrazita logika ima primjenu i pri formiranju adaptacijskog mehanizma [67]. Tako

se u ovoj doktorskoj disertaciji pri **ON**-line vođenju mobilnog robota predlože neizraziti oblik Kalman-Busijevog filtera kao adaptacijskog mehanizma u svrhu smanjivanja mjernog šuma i prikazuju rezultati simulacije u slučaju stacionarnog i nestacionarnog ergodičnog mjernog »bijelog šuma« te se tako dobiveni rezultati uspoređuju sa klasičnim Kalman-Busijevim filterom. Nakon razrade postavljenog zadatka hipotezom rada, slijedi u sedmom poglavlju zaključak rada i daljnje smjernice rada, a na kraju osmim poglavljem daje se zaključak doktorskog rada. Od poznatih programskih paketa [52,83,84], u ovoj doktorskoj disertaciji korišteni su programski moduli koji su realizirani tehničkim okruženjem programskog paketa **MATLAB** – (**MAT**rični – **LAB**oratorij) i koji su dani prilogima na kraju doktorske disertacije.

1.5 Hipoteza rada

S obzirom na prethodno stečena iskustva izradom magistarskog rada [40], na početku izrade ove doktorske disertacije postavljena je slijedeća hipoteza rada:

Određenim promjenama u postojećoj strukturi analitičkog neizrazitog regulatora moguće je dobiti njegove bolje regulacijske karakteristike. Isto tako moguće je izgraditi zadovoljavajuće samoorganiziranje tog regulatora u smislu adaptacije njegovih parametara s ciljem što uspješnijeg vođenja mobilnog robota po definiranoj nominalnoj trajektoriji.

2. SUVREMENI NEIZRAZITI ANALITIČKI REGULATOR

2.1 Osnovni pojmovi neizrazitog analitičkog regulatora


Razumijevanje rada Neizrazitog Analitičkog Regulatora (NAR-a) u svojoj osnovi podrazumijeva potpuno ovladavanje osnovnim pojmovima suvremenog analitičkog pristupa neizrazitoj regulaciji, [30,31,32,33,34,85,86]. U nastavku se uvode i definiraju pojmovi kao što su usvojeni novi adaptivni oblici funkcija pripadnosti neizrazitom skupu [44,45], normalizacija ulazne varijable, ε - β distribucija raščlanjenosti neizrazitih skupova, aktivacijska funkcija i funkcija preslikavanja ulazne varijable na položaj centra izlaznog neizrazitog skupa.

2.1.1 Novi oblik funkcije pripadnosti neizrazitom skupu

Ako sa A_j označimo neizraziti skup j -te ulazne varijable $x \in X$, koja pripada skupu $X = \{x_o, \dots, x_e\}$ ograničenom svojom minimalnom x_o i maksimalnom vrijednosti x_e , onda za te rubne vrijednosti ulazne varijable neizrazitog skupa A_j funkcija pripadnosti $S(x)$ mora udovoljavati slijedećim rubnim uvjetima

$$S(x_o) : x_o \in X \rightarrow 0, \quad S(x_e) : x_e \in X \rightarrow 0, \quad (2.1)$$

gdje nulta vrijednost funkcije pripadnosti osim označavanja početka i kraja novog oblika neizrazitog skupa govori o potpunoj nepripadnosti varijabli sa rubova područja rasprave X neizrazitom skupu definiranom funkcijom pripadnosti $S(x)$ (slika 2.1a).



Slika 2.1 Novi oblik funkcije pripadnosti neizrazitog skupa, a) $S(x)$ i b) normirani skup $S(\underline{x})$

Neizraziti skup je simetričan na svoju vertikalnu središnju os koja je određena s centralnom ili središnjom vrijednosti (x_c). Slijedeće svojstvo funkcije pripadnosti proizlazi iz centralnog uvjeta

$$S(x_c) : x_c \in X \rightarrow 1 \quad , \quad (2.2)$$

koji kazuje da za različite oblike neizrazitog skupa pri središnjoj vrijednosti ulazne varijable postoji potpuna pripadnost neizrazitom skupu, odnosno pri toj vrijednosti funkcijom pripadnosti definirana je točka koja predstavlja centroid, središte ili nukleus neizrazitog skupa. Novim oblikom neizrazitog skupa [30] nukleus je moguće sa jedne točke $x=x_c$ proširiti na interval $x \in X_c$ određen skupom $X_c = \{x_a, \dots, x_b\}$ gdje x_a i x_b predstavljaju granične vrijednosti ulaznih varijabli tog skupa. Stoga možemo pisati da vrijedi:

$$x_c = \frac{x_o + x_e}{2} = \frac{x_a + x_b}{2} \quad . \quad (2.3)$$

Kako je razlikom maksimalne i minimalne vrijednosti $T = x_e - x_o$ iz područja razmatranja ulazne varijable X dana osnova ili baza neizrazitog skupa, na osnovu nje je moguće definirati adaptacijski parametar ε s kojim podešavamo granice skupa X_c za čije elemente općenito vrijedi $S(x) : x \subseteq X_c \rightarrow 1$

$$\varepsilon = \frac{T}{x_b - x_a} \quad . \quad (2.4)$$

Na osnovu jednadžbi (2.3) i (2.4) dolazi se do slijedećih općenitih relacija neizrazitog skupa:

$$x_a = x_c - \frac{T}{2 \cdot \varepsilon} \quad , \quad x_b = x_c + \frac{T}{2 \cdot \varepsilon} \quad . \quad (2.5)$$

Za vrlo veliku vrijednost parametra ε , funkcija pripadnosti neizrazitog skupa $S(x)$ po svom obliku teži kosinusnom trokutu kojeg dostiže pri beskonačnoj vrijednosti parametra ε . Iz prethodnih izraza vidljivo je da za beskonačnu vrijednost parametra ε , x_a i x_b padaju u središnju vrijednost neizrazitog skupa x_c za koju vrijedi potpuna pripadnost neizrazitom skupu dana izrazom (2.2). Kada parametar ε teži jedinici onda funkcija pripadnosti neizrazitog skupa teži obliku kosinusnog pravokutnika, dok za vrijednosti određene nejednadžbom $1 < \varepsilon < \infty$ funkcija pripadnosti ima oblik kosinusnog trapezoida. Na osnovu definirane baze neizrazitog skupa T , neposredno iz izraza (2.3) slijede izrazi:

$$x_o = x_c - \frac{T}{2} \quad , \quad x_e = x_c + \frac{T}{2} \quad . \quad (2.6)$$

Funkcija pripadnosti (eng. *membership function*) za različite intervale vrijednosti ulazne varijable (slika 2.1a) definirana je sljedećim jednadžbama [40]:

$$\text{za: } x_o \leq x < x_a \quad S(x) = \frac{S_{\max}}{2} \cdot \left[1 - \cos \frac{\pi \cdot (x - x_o)}{x_a - x_o} \right], \quad (2.7)$$

$$\text{za: } x_a \leq x \leq x_b \quad S(x) = S_{\max}, \quad (2.8)$$

$$\text{za: } x_b < x \leq x_e \quad S(x) = \frac{S_{\max}}{2} \cdot \left[1 - \cos \frac{\pi \cdot (x_e - x)}{x_e - x_b} \right], \quad (2.9)$$

gdje $S_{\max}=1$ iskazuje potpunu pripadnost neizrazitom skupu u intervalu (2.8), čiji raspon na osnovu poznate baze neizrazitog skupa T zapisujemo u obliku

$$x_b - x_a = \frac{T}{\varepsilon} = T_2. \quad (2.10)$$

Jednake raspone intervala dane izrazima (2.7) i (2.9) na osnovu jednadžbi (2.5-6) zapisujemo u obliku

$$x_a - x_o = x_e - x_b = \frac{T \cdot (\varepsilon - 1)}{2 \cdot \varepsilon} = T_1, \quad (2.11)$$

tako da se na osnovu dobivenih jednadžbi (2.6, 2.10-11) uz adaptacijski parametar ε i bazu neizrazitog skupa T , funkcije pripadnosti dane izrazima (2.7-9) dobivaju u konačnom obliku:

$$\text{za: } x_o \leq x < x_a \quad S(x) = \frac{1}{2} \cdot \left[1 - \cos \frac{2\pi \varepsilon \cdot (x - x_o + T/2)}{T(\varepsilon - 1)} \right], \quad (2.12)$$

$$\text{za: } x_a \leq x \leq x_b \quad S(x) = 1, \quad (2.13)$$

$$\text{za: } x_b < x \leq x_e \quad S(x) = \frac{1}{2} \cdot \left[1 - \cos \frac{2\pi \varepsilon \cdot (x_e + T/2 - x)}{T(\varepsilon - 1)} \right]. \quad (2.14)$$

Za odabrane vrijednosti parametara $x_o=0$, $T=2$ i $\varepsilon=7$, funkcija pripadnosti neizrazitom skupu prikazana je na slici 2.1a.

2.1.2 Normalizacija ulazne varijable

Određivanjem područja $X \subset \mathbb{R}$ razmatranja ulazne varijable $x \in X$ kao pravog podskupa realnih brojeva i utvrđivanjem maksimalne vrijednosti iz tog skupa $|x_{\max}|$, stečeni su osnovni preduvjeti za normalizaciju ulazne varijable x funkcijom preslikavanja oblika

$$\frac{x}{|x_{\max}|} : x \in X \subset \mathbb{R} \rightarrow \underline{x} \in \underline{X}, \quad (2.15)$$

gdje normaliziranu ulaznu varijablu \underline{x} kao komponentu normaliziranog skupa $\underline{X} = \{-1, \dots, 1\}$ dobivamo prethodno definiranom funkcijom preslikavanja (2.15) odnosno izrazom

$$\underline{x} = \frac{x}{|x_{max}|} \quad . \quad (2.16)$$

Primjenom ovog izraza i uvjeta simetričnosti neizrazitog skupa $|x_o| = |x_e| = |x_{max}|$, iz jednadžbi (2.12-14) dobiva se vrijednost funkcije pripadnosti normalizirane ulazne varijable neizrazitom skupu u slijedećem obliku:

$$\text{za: } -1 \leq \underline{x} < \underline{x}_a \quad S(\underline{x}) = \frac{1}{2} \cdot \left[1 - \cos \frac{2\pi \varepsilon \cdot (\underline{x} - \underline{x}_c + T/2)}{T(\varepsilon - 1)} \right] \quad , \quad (2.17)$$


$$\text{za: } \underline{x}_a \leq \underline{x} \leq \underline{x}_b \quad S(\underline{x}) = 1 \quad , \quad (2.18)$$

$$\text{za: } \underline{x}_b < \underline{x} \leq 1 \quad S(\underline{x}) = \frac{1}{2} \cdot \left[1 - \cos \frac{2\pi \varepsilon \cdot (\underline{x}_c + T/2 - \underline{x})}{T(\varepsilon - 1)} \right] \quad , \quad (2.19)$$

o čemu za odabrane vrijednosti parametara $\underline{x}_c=0$, $T=2$ i $\varepsilon=7$, govori i prikazana funkcija pripadnosti normiranom neizrazitom skupu na slici 2.1b.

2.1.3 $\varepsilon\beta$ distribucija raščlanjenosti ulaznih neizrazitih skupova

Nakon uvođenja konvencionalnog pristupa neizrazitoj regulaciji [1,2,3] pojam raščlanjenosti neizrazitih skupova, sa ciljem pravilnog tumačenja obrazlaže se u par navrata [68], tako da se s rađanjem novog suvremenog analitičkog pristupa neizrazitoj regulaciji javila potreba novog tumačenja tog pojma, koja se daje u nastavku. Nad područjem razmatranja $\underline{X}_j = \{-1, \dots, \underline{x}_j, \dots, 1\}$ j -te ulazne normalizirane varijable $\underline{x}_j \in \underline{X}_j$ ($j=1,2,\dots,m$) gdje m predstavlja ukupan broj ulaznih varijabli **NAR**-a za različite vrijednosti adaptacijskog parametra ε_i^j ($i=1,2,\dots,p_j$) definiraju se funkcijama pripadnosti (2.17-19) p_j neizraziti skup. Ukupan broj definiranih neizrazitih skupova (p_j) ovisi o zadatku regulacije i ograničen je kapacitetom ili/i brzinom mikroprocesora. Ukupan broj ulaznih varijabli prvenstveno je uvjetovan zadatkom regulacije, a vrijednosti ulazne varijable u pojedinim normaliziranim vremenski diskretnim koracima (n) mogu biti definirane ili odstupanjima po poziciji $x=-e(n)$, brzini $x=-de(n)$ ili/i prethodnim vrijednostima regulacijske veličine $x=u_r(n-1)$ [31,32,33,35,40]. Definirane funkcije pripadnosti (2.17-19) pri različitim iznosima parametra ε_i iskazuju pripadnost j -te ulazne varijable i -tom neizrazitom skupu A_i^j i na taj način doprinose raščlanjivanju područja razmatranja \underline{X}_j po skupovima neizrazitih vrijednosti sa zajedničkim svojstvom da pri središnjoj vrijednosti ulazne varijable x_c postoji njezina potpuna pripadnost svim neizrazitim skupovima (slika 2.2).




Slika 2.2 Raščlanjenost ulaznih neizrazitih skupova parametrom $\varepsilon = 1,28; 1,55; 2; 3,2; 7$ i 120 .

Finija raspodjela ulaznih neizrazitih skupova j -te ulazne varijable \underline{x}_j postiže se variranjem β parametra [30], čime se direktno utječe na postojeću funkciju pripadnosti (2.17-19) čijom modifikacijom neposredno slijedi

$$\text{za: } 0 \leq |\underline{x}_j| < \frac{T_i}{2\varepsilon_i}, \quad S(\underline{x}_j) = 1, \quad i=1,2,\dots,p_j, \quad j=1,2,\dots,m. \quad (2.20)$$

$$\text{za: } \frac{T_i}{2\varepsilon_i^j} \leq |\underline{x}_j| \leq \frac{T_i}{2}, \quad S(\underline{x}_j) = \frac{1}{2 \cdot \exp(\beta_j \varepsilon_i^j |\underline{x}_j|)} \cdot \left[1 - \cos \frac{2\pi \varepsilon_i^j \cdot ((\underline{x}_{ci} - \underline{x}_j) \operatorname{sgn}(\underline{x}_j) + T_i/2)}{T_i(\varepsilon_i^j - 1)} \right]. \quad (2.21)$$

Prethodnim izrazima predstavljena je ε - β distribucija ulaznih neizrazitih skupova [30], gdje je ε - parametar zadužen za oblik funkcije pripadnosti a β - parametar za raspodjelu iste unutar područja razmatranja \underline{X}_j j -te normalizirane ulazne varijable $\underline{x}_j \in \underline{X}_j$. Za usvojene zajedničke položaje centra $\underline{x}_{ci}^j = 0$ i baze $T_i^j = \underline{x}_{ei}^j - \underline{x}_{oi}^j$ i -tih neizrazitih skupova A_i^j , j -te ulazne varijable \underline{x}_j , pri čemu je $\underline{x}_{oi}^j = -1$, $\underline{x}_{ei}^j = +1$ i odabrane adaptacijske parametre $\varepsilon = 1,28; 1,55; 2; 3,2; 7$ i 120 prikazane su na (slici 2.3) raspodjele funkcija pripadnosti $S(\underline{x}_j)$ za različite vrijednosti usvojenog β -parametra. Pri konstantnoj vrijednosti j -te ulazne normalizirane varijable \underline{x}_j , se sa povećanjem adaptacijskog parametra β dolazi do smanjenja vrijednosti i -te funkcije pripadnosti $S(\underline{x}_j)$, što rezultira povećanjem strmine karakteristične upravljačke površine oko radne točke, odnosno povećanjem osjetljivosti **NAR**-a.



Slika 2.3 Grafički prikazi ε - β distribucije raščlanjenosti ulaznih neizrazitih skupova (slika 2.2), definiranih funkcijama pripadnosti (2.20-21)

2.1.4 Analitički oblik aktivacijske funkcije i funkcije preslikavanja za određivanje položaja centara izlaznih neizrazitih skupova

Svaka j -ta ulazna varijabla **NAR**-a aktivira samo jedan izlazni neizraziti skup B_j sa svojom funkcijom pripadnosti S_{B_j} . Aktiviranje izlaznog neizrazitog skupa vrši se aktivacijskom funkcijom ω_j koja je jednaka sumi vrijednosti funkcija pripadnosti sa kojima je j -ta ulazna varijabla \underline{x}_j raščlanjena po i -tim ulaznim neizrazitim skupovima A_i^j . Kod suvremenog analitičkog pristupa neizrazitoj regulaciji aktivacijska funkcija u analitičkom obliku glasi

$$\omega_j = \underline{S}_1^j(\underline{x}_j) + \underline{S}_2^j(\underline{x}_j) + \dots + \underline{S}_{p_j}^j(\underline{x}_j) = \sum_{i=1}^{p_j} \underline{S}_i^j(\underline{x}_j) . \quad (2.22)$$

Kako je pri većim iznosima normalizirane ulazne varijable njezina raščlanjenost u neizrazitim skupovima manja (slika 2.3), onda je vrijednost aktivacijske funkcije dobivena prethodnim


izrazom također manja. U svrhu određivanja položaja centra y_{cj} izlaznog neizrazitog skupa B_j definira se funkcija $f_{cj}(\underline{x}_j)$

$$f_{cj} : \underline{x}_j \in \underline{X} \subseteq \mathbb{R}^{p_j} \rightarrow \underline{y}_{cj} \in \mathbb{R}, \quad (2.23)$$

koja vrši preslikavanje ulazne j -te varijable \underline{x}_j , ulaznog i -tog normaliziranog neizrazitog skupa ($i=1,2,\dots,p_j$) na normaliziranu poziciju centra izlaznog neizrazitog skupa \underline{y}_{cj} u analitičkom

$$\text{obliku} \quad \left| \underline{y}_{cj} \right| = 1 - \frac{1}{p_j} \cdot \sum_{i=1}^{p_j} \underline{S}_i^j(\underline{x}_j) = 1 - \frac{\omega_j}{p_j}, \quad j = 1, 2, \dots, m. \quad (2.24)$$

Iz (2.24) neposredno slijedi da je kod većih iznosa normalizirane ulazne varijable veća i apsolutna vrijednost normalizirane pozicije centra izlaznog neizrazitog skupa. Za četiri različite ε - β distribucije raščlanjenosti ulaznih neizrazitih skupova (slika 2.3), primjenom funkcije preslikavanja (2.24) na sve vrijednosti j -te ulazne varijable $\underline{x}_j \in \underline{X}_j$, prikazane su na (slici 2.4) apsolutne normalizirane vrijednosti pozicija centara j -tog izlaznog neizrazitog skupa.



Slika 2.4 Apsolutna normalizirana vrijednost pozicije centara izlaznih neizrazitih skupova $|Y_{cj}(\underline{x}_j)|$, za ε - β distribuciju raščlanjenosti ulaznih neizrazitih skupova (slika 2.3).

Kako je upravljačka veličina direktno proporcionalna položajima centara izlaznih neizrazitih skupova j -tih ulaznih varijabli, onda se s ciljem afirmiranja korekcijskog djelovanja regulacijske veličine prethodni izraz zapisuje u slijedećem obliku

$$\underline{y}_{cj} = \left(1 - \frac{\omega_j}{p_j}\right) \cdot \text{sgn}(\underline{x}_j) \quad , \quad j = 1, 2, \dots, m \quad . \quad (2.25)$$

Iz izraza (2.25) neposredno slijedi da algebarskoj vrijednosti odstupanja regulirane veličine odgovara i algebarska vrijednost položaja centra izlaznog neizrazitog skupa. Pritom se zadržava nulta vrijednost pozicije centra izlaznog neizrazitog skupa jedino kod nultog odstupanja regulirane veličine, kad postoji njezina potpuna pripadnost svim ulaznim neizrazitim skupovima. Funkcija preslikavanja j -te ulazne varijable na poziciju centra izlaznog neizrazitog skupa daje se u konačnom obliku

$$y_{cj} = K_{cj} \cdot \underline{y}_{cj} = U_m F_j \left(1 + |\underline{x}_j|^{\alpha_j}\right) \cdot \left(1 - \frac{\omega_j}{p_j}\right) \cdot \text{sgn}(\underline{x}_j) \quad , \quad (2.26)$$

pri čemu U_m označava maksimalnu vrijednost regulacijske veličine **NAR-a**, F_j i α_j predstavljaju slobodne parametre koji se ovisno o zadatku regulacije određuju u svakom konkretnom slučaju. Uvedeno pojačanje položaja centra izlaznog neizrazitog skupa označeno s K_{cj} dano je izrazom

$$K_{cj} = U_m F_j \left(1 + |\underline{x}_j|^{\alpha_j}\right) \quad \text{uz} \quad U_m > 0, \quad F_j > 0, \quad \alpha_j \geq 0 \quad . \quad (2.27)$$

Iz (2.27) neposredno slijedi da za nultu odabranu vrijednost slobodnog parametra α_j izostaje adaptivno pojačanje, te se u tom slučaju na pojačanje može jedino utjecati izborom slobodnog parametra F_j .

2.2 Osnovna svojstva i smjernice u razvoju analitičkog pristupa neizrazitoj regulaciji

Općenitu primjenu neizraziti regulatori nalaze u sustavima linearne i/ili nelinearne prirode koji se teško modeliraju ili ih uopće nije moguće modelirati [31,32,33,35,40,85,86]. Stoga se općenito dobra svojstva primjene neizrazite upravljačke logike iznose u najkraćim crtama.

- a) Neizraziti regulatori nalaze svoju najveću primjenu u sustavima regulacije čiju je dinamiku teško ili nije moguće opisati. Ipak projektiranju neizrazitog regulatora treba pristupiti nakon prethodne detaljne analize reguliranih procesa. Dio potrebnog modeliranja sadržan je u iskustvu eksperta, koji u takvim okolnostima postaju od velike koristi pri projektiranju neizrazitih sustava regulacije [26,27,28,29].

- b) Nelinearni način rada koji proizlazi iz strukture neizrazitog regulatora nudi raznolike mogućnosti u rješavanju nekih teških problema pri poboljšanju kvalitete regulacije.
- c) Neizrazitim regulatorima nadomještaju se klasični regulatori zbog boljeg ponašanja s obzirom na stabilnost, veće tolerancije kod pogrešaka u razvoju, te zbog velike robusnosti u odnosu na promjenu parametara sustava regulacije [60,61,62]. To pogotovo vrijedi za procese viših redova (npr. kod fleksibilnog robota) i procese s mrtvim vremenom.
- d) Projektiranje neizrazitih regulatora postaje relativno jednostavno, pogotovo kod kompleksnih sustava regulacije, kod kojih se u pravilu postižu kratka razvojna vremena i zadovoljavajuća kvaliteta regulacije [69].
- e) U usporedbi s klasičnim (konvencionalnim) regulatorima neizraziti regulatori zahtijevaju manju točnost senzora i mjernih pretvarača.
- f) Neizraziti regulatori omogućuju fleksibilnu upotrebu za poboljšanje kvalitete regulacije, te je moguće njihovo korištenje kod mješovitih krugova regulacije, gdje prvenstveno služe za adaptivnu prilagodbu klasičnih regulatora u promijenjenim uvjetima i zadacima nadzora procesa [63,64,65,66,67].
- g) Jedna je od prednosti neizrazitih regulatora jednostavno razumijevanje njihova rada, što omogućuje njihovo projektiranje, optimiranje i korištenje od strane osoblja koje nije usko specijalizirano.

Dalje se navode loša svojstva neizrazite upravljačke logike.

- a) Jedna od značajnijih loših osobina je heuristički postupak projektiranja i testiranja neizrazitih sustava regulacije i regulatora – najčešće metodom pokušaja i pogreške.
- b) Budući da je neizraziti regulator nelinearni regulator, određivanje stabilnosti nije uvijek jednostavno.
- c) Izbor broja i oblika funkcija pripadnosti u velikoj je mjeri ovisna o iskustvu projektanta, što znači da je o iskustvu ovisna kvaliteta regulacije [16,18,19].
- d) Postupci izoštravanja (defazifikacije), također su subjektivne prirode, što izravno utječe na kvalitetu regulacije.
- e) Vrlo često je podešavanje parametara neizrazitog regulatora dugotrajan i zamoran posao [40].
- f) Nema neposrednog nadzora nad procesom projektiranja – ne prihvaća se za sada kao rješenje u kritičnim procesima (elektrane, kemijska industrija, zrakoplovna industrija i sl.).

Osnovno svojstvo **NAR**-a je da ne postoji ograničenja kako u broju ulaznih i izlaznih varijabli tako i u broju ulaznih neizrazitih skupova pridruženih ulaznim varijablama. Ovim je izravno riješen problem vezan za konvencionalne neizrazite regulatore kod kojih sa povećanjem broja ulaznih varijabli eksponencijalno se povećava broj potrebnih pravila regulacije, čime postaje upitna njihova upotrebljivost u realnom vremenu [15]. Kod konvencionalne neizrazite logike dobro poznato geslo da »dovoljan broj neizrazitih pravila regulacije, može aproksimirati bilo koju nepoznatu funkciju« je suvremenim pristupom neizrazitoj regulaciji zamijenjeno sa novim opravdanim prijedlogom: »dovoljan broj slobodnih parametara neizrazitog regulatora može aproksimirati bilo koju nepoznatu analitičku funkciju« [30]. Neka je u općenitom slučaju sa (m) označen ukupan broj ulaznih varijabli **NAR**-a, gdje svaka j -ta ulazna varijabla ($j=1,2,\dots,m$) ima ukupno p_j ulaznih neizrazitih skupova i jedan izlazni neizraziti skup, pri čemu broj neizrazitih skupova p_j je ograničen kapacitetom ili/i brzinom digitalnog računala. Vrijednost adaptacijskog parametra ε_i^j ($i=1,2,\dots,n_j, j=1,2,\dots,m$), općenito je različita za svaki ulazni neizraziti skup. Ako se sa elementima $N_{\varepsilon 1}, N_{\varepsilon 2}, N_{\beta}, N_F, N_a$ i N_T označe svi slobodni parametri suvremenog neizrazitog regulatora, pri čemu vrijedi da je $N_{\varepsilon 1}=p_1+p_2+\dots+p_m$ i $N_{\beta}=N_F=N_a=N_T=N_{\varepsilon 2}=m$, onda je ukupan broj slobodnih parametara **NAR**-a jednak $N_P = p_1+p_2+\dots+p_m+5m$, dok ukupan broj pravila regulacije kod konvencionalnog neizrazitog regulatora iznosi $N_R=n_1 \cdot n_2 \cdot n_3 \dots n_m$. Na primjer prilikom projektiranja neizrazitog upravljačkog **FLC** (eng. *Fuzzy Logic Control*) sustava mobilnog robota u magistarskom radu [40], je sa stajališta **MISO** (eng. *Multi-Input-Single-Output*) sustava na nivou svakog stupnja slobode gibanja bilo potrebno tri ulazne ($m=3$) i jedna izlazna varijabla što je pri $m=3$ i $p_1=p_2=p_3=10$ kod **NAR**-a zahtijevalo ukupno $N_P = p_1+p_2+p_3+5m=45$ parametara, a kod konvencionalnog neizrazitog analitičkog regulatora $N_R = p_1 p_2 p_3 = 1000$ pravila regulacije. U slučaju izraženog dinamičkog sprežanja između stupnjeva slobode gibanja mobilnog robota, je sa stajališta **MIMO** (eng. *Multi-Input-Multi-Output*) sustava potrebno je šest ulaznih ($m=6$) i dvije izlazne varijable ($p=2$), odnosno ukupno $N_P = p_1+p_2+\dots+p_m+5pm=102$ parametara, dok implementacija konvencionalnog neizrazitog regulatora zahtjeva rekordnih $N_R = p \cdot n_1 \cdot n_2 \cdot n_3 \cdot n_4 \cdot n_5 \cdot n_6 = 2000000$ pravila regulacije. Dakle daleko manji broj slobodnih parametara potreban je kod suvremenog neizrazitog regulatora nego kod klasične neizrazite regulacije temeljene bazom pravila regulacije. To je i jedna od najvažnijih prednosti suvremene neizrazite regulacije, kao i činjenica da svi N_P parametri suvremenog neizrazitog regulatora mogu biti adaptirani kao odgovarajuće funkcije diskretnog vremena. To ujedno i predstavlja jednu od smjernica njegovog razvoja. Stoga se razvija suvremeni pristup neizrazitoj regulaciji kod kojega se višestruko izlazni **MIMO** sustav, koji nema izlazno-ulaznih

interakcija, razdvaja u skup **MISO** sustava sa jednim izlazom. Pritom se umjesto formiranja baze pravila ponašanja uvodi analitička funkcija preslikavanja ulazne j -te varijable na poziciju centra izlaznog neizrazitog skupa (eng. *fuzzy set*). Suvremeni analitički pristup neizrazitoj regulaciji u svom razvoju objedinjuje četiri osnovne smjernice:

- a) Uvođenje novih oblika ulaznih neizrazitih skupova adaptiranih parametrom ε_i^j ($i=1, \dots, p_j, j=1, \dots, m$), gdje p_j predstavlja broj neizrazitih skupova j -te ulazne varijable, a m ukupan broj ulaznih varijabli, i nove finije raspodjele ulaznih neizrazitih skupova čija raščlanjenost je definirana parametrom β_j , što je važno za slijedeće dvije smjernice razvoja.
- b) Pri suvremenom analitičkom pristupu rješavanja logike neizrazite regulacije, potrebno je nasuprot konvencionalnom pristupu neizrazitoj regulaciji umjesto, max–min ili max-prod operatora kompozicije [70,71], usvojiti analitičku aktivacijsku funkciju s kojom pri određenoj vrijednosti ulazne varijable x_j pridružujemo odgovarajuću težinu izlaznom neizrazitom skupu.
- c) Treća vrlo važna smjernica u razvoju analitičkog pristupa neizrazitoj regulaciji je određivanje analitičke funkcije, za preslikavanje ulaznih varijabli na pozicije centara izlaznih neizrazitih skupova umjesto formiranja pravila baze ponašanja, što je jedan od mogućih načina da se izbjegne eksponencijalni rast pravila što se više povećava broj ulaznih varijabli.
- d) Posljednja smjernica u razvoju je formiranje analitičkog izraza za izračunavanje izlaza (eng. defuzzification) kao funkcije pozicija centara i oblika izlaznih neizrazitih skupova te njihovih aktivacijskih funkcija.


Prethodne četiri navedene smjernice svojom analitičkom procedurom, su se pokazale nužne za razvoj analitičkog pristupa neizrazitoj regulaciji podržavajući na taj način koncept sinteze neizrazitog regulatora bez upotrebe bilo kojeg pravila neizrazite logike [30,31,32,33,85,86]. Dakle u nastavku izlaganja ove doktorske disertacije, u tom pravcu biti će predložena daljnja poboljšanja postojeće strukture **NAR**-a.

2.3 Struktura neizrazitog analitičkog regulatora

Konvencionalni **FLC** sustav se principijelno sastoji od četiri osnovna elementa [43], kao što je to prikazano na (slici 2.5)

1. Baze pravila regulacije (eng. *fuzzy rule base*)
2. Decimalno-neizrazite (**D/N**) pretvorbe, (eng. *fuzzification*)

3. Procesu odlučivanja (eng. *inference*)
4. Neizrazito-decimalne (N/D) pretvorbe, (eng. *defuzzification*)



Slika 2.5 Princip rada konvencionalnog neizrazitog regulatora

Kod suvremenog analitičkog pristupa neizrazitoj regulaciji (B/N) pretvorbu sa adaptivnim oblicima ulaznih neizrazitih skupova (slika 2.2) vršimo izrazima (2.17-19) ili izrazima (2.20-21) sa ε - β distribucijom raščlanjenosti ulaznih neizrazitih skupova (slika 2.3).

Korištenjem analitičke funkcije preslikavanja ulaznih varijabli na pozicije centara izlaznih neizrazitih skupova (2.26) izbjegnuto je eksponencijalni porast broja pravila regulacije s brojem ulaznih varijabli. Ovo nasuprot konvencionalnom pristupu ne zahtjeva formiranje baze pravila regulacije i samim tim predstavlja osnovu suvremenog analitičkog pristupa neizrazitoj regulaciji.


Kod konvencionalnog pristupa neizrazitoj regulaciji u procesu odlučivanja max-min je bio najčešći operator kompozicije no nije u potpunosti podržan od strane eksperimentalnih dokaza i teorijskih razmatranja. Zadeh [2] koji je 1965. godine uveo neizrazite skupove kao generalizaciju na konvencionalnu teoriju skupova, priznaje da u nekim kontekstima operatori unije/presjeka (eng. *Union/intersection*) trebaju biti algebarska suma/produkt prije nego max-min operatori, ali nije ukazano koji od tih dvaju operatora kompozicije i u kojim slučajevima treba primijeniti. Kod suvremenog pristupa neizrazitoj regulaciji aktivacijska funkcija ω_j dana u analitičkom obliku (2.22) uspješno zamjenjuje Mamdanijev max-min operator kompozicije [6], doprinoseći na taj način stupnju težine izlaza NAR-a. Do izlazne upravljačke veličine $u_r(n+1)$ u normaliziranoj vremenski diskretnoj točki (n) NAR-a, dolazi se (N/B) pretvorbom koristeći se metodom težišta COG (eng. *Center Of Gravity method*) ili površina COA (eng. *Center Of Area method*),

$$u_F(n+1) = \frac{\int y(n) \cdot S_o(y, n) dy}{\int S_o(y, n) dy}, \quad (2.28)$$

čiji je detaljan izvod za **NAR** dan u [32,85], a prikazan je i u magistarskom radu [40], a ovdje ga dajemo u konačnom obliku:

$$u_F(n+1) = \frac{\sum_{j=1}^m \left(\omega_j(n) \cdot y_{cj}(n) \cdot T_j \cdot \frac{(\varepsilon_{oj} + I)}{2 \cdot \varepsilon_{oj}} \right)}{\sum_{j=1}^m \left(\omega_j(n) \cdot T_j \cdot \frac{(\varepsilon_{oj} + I)}{2 \cdot \varepsilon_{oj}} \right)}, \quad (2.29)$$

gdje ε_{oj} označava adaptacijski parametar, a T_j bazu izlaznog neizrazitog skupa. Dakle u svojoj osnovi suvremeni analitički pristup neizrazitoj regulaciji [30,85], zasniva se na tri analitičke skalarne jednačbe (2.22, 2.26 i 2.29), čiji osnovni princip rada je prikazan na slici 2.6.



Slika 2.6 Princip rada analitičkog neizrazitog regulatora

2.4 Struktura poboljšanog neizrazitog analitičkog regulatora

2.4.1 Postupak Decimalno-Neizrazite (D/N) pretvorbe

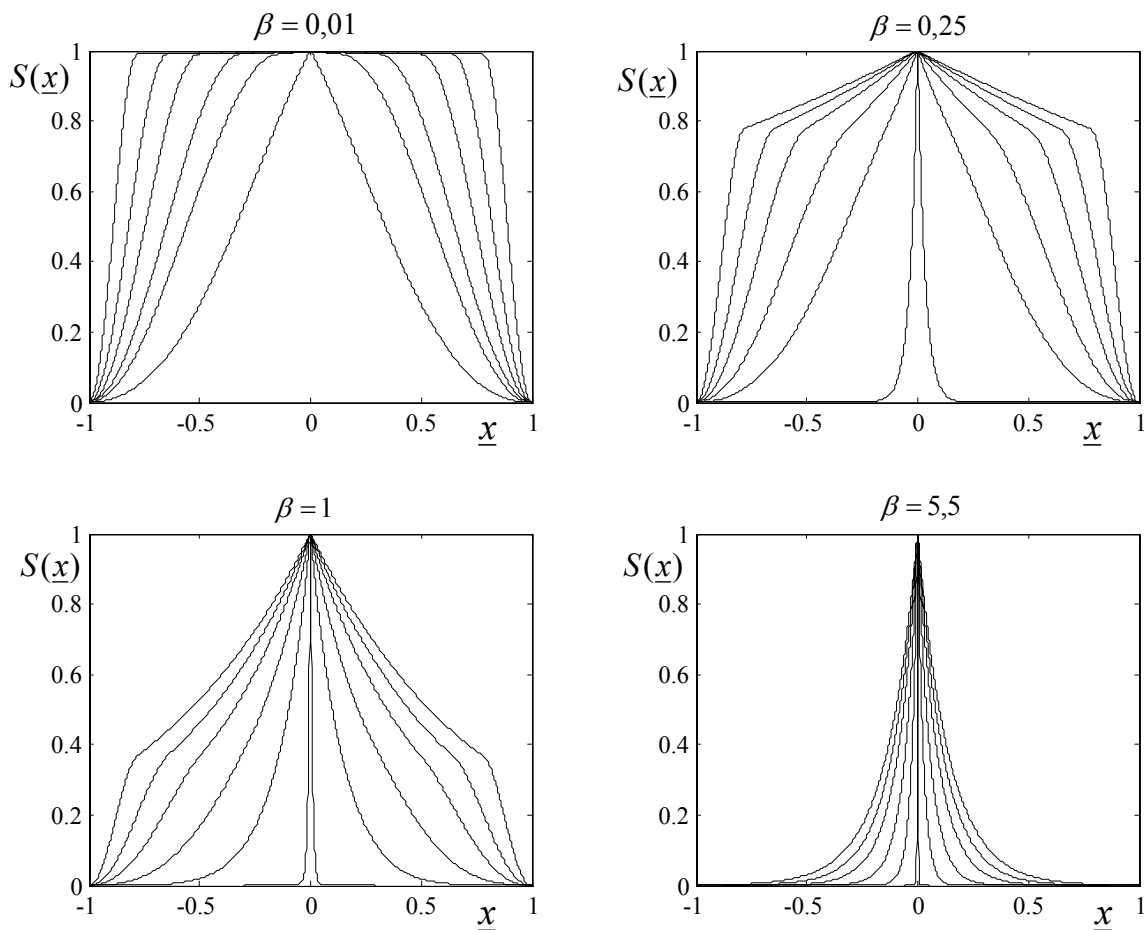
Općenito, poboljšanje **NAR**-a može ići u pravcu svih smjernica njegovog razvoja. Pri dosadašnjem pristupu granica intervala potpune pripadnosti j -te ulazne varijable i -tom neizrazitom skupu A_i^j se primjenom finije β distribucije raščlanjenosti ulaznih neizrazitih skupova nije mijenjala (slika 2.3). Povećanjem β parametra jedino se je utjecalo na smanjenje vrijednosti funkcije pripadnosti za sve ostale vrijednosti ulazne varijable, što nakon primjene funkcije preslikavanja (2.24), na granicama intervala potpune pripadnosti uzrokuje nagle promjene u apsolutnim vrijednostima pozicije centra izlaznog neizrazitog skupa. Ovo za posljedicu ima nazubljenje karakteristične upravljačke krivulje (slika 2.4). Primjena takvog upravljanja ima smisla pri manjim vrijednostima β parametra, dok pri većim vrijednostima ima jedino smisla sa dinamičkog stajališta, pri čemu je β parametar adaptiran kao odgovarajuća funkcija diskretnog vremena. Pri takvom pristupu izloženom referencama [31,32,33], **NAR** je u jednom trenutku svojevrsni generator perturbacija, dok u sljedećem trenutku ima upravljačka svojstva. Neizbježni skokovi upravljačke varijable na granicama potpune pripadnosti

neizrazitom skupu posljedica su postojanja diskontinuiranosti karakteristične krivulje upravljanja pri čemu vrijednosti viših derivacija, kad se tim mjestima približavamo s lijeve i desne strane nemaju istu vrijednost. Zato pri takvom pristupu postupci samoorganiziranja slobodnih parametara **NAR**-a zasnovani na gradijentu pogreške imaju samo ograničenu primjenu. Stoga se uvođenjem suvremenog analitičkog pristupa, u svrhu poboljšanja postojećih karakteristika uvode i novi oblici funkcija pripadnosti ulaznih neizrazitih skupova

$$\text{za: } 0 \leq |\underline{x}_j| < \frac{T_i}{2\varepsilon_i}, \quad S(\underline{x}_j) = \frac{I}{\exp(\beta_j \varepsilon_i^j |\underline{x}_j|)}, \quad i=1,2,\dots,p_j, \quad j=1,2,\dots,m, \quad (2.30)$$

$$\text{za: } \frac{T_i}{2\varepsilon_i^j} \leq |\underline{x}_j| \leq \frac{T_i}{2} \quad S(\underline{x}_j) = \frac{1}{2 \cdot \exp(\beta_j \varepsilon_i^j |\underline{x}_j|)} \cdot \left[1 - \cos \frac{2\pi \varepsilon_i^j \cdot ((\underline{x}_j - \underline{x}_{ci}) \operatorname{sgn}(\underline{x}_j) + T_i/2)}{T_i(\varepsilon_i^j - 1)} \right], \quad (2.31)$$

pri čemu se dosadašnja upravljačka svojstva **NAR**-a poboljšavaju nad čitavim područjem razmatranja ulazne varijable $\underline{x}_j \in \underline{X}_j \subset \mathbb{R}$.



Slika 2.7 Grafički prikazi ε - β distribucije raščlanjenosti ulaznih neizrazitih skupova (slika 2.2), definiranih funkcijama pripadnosti (2.30-31) pri različitim vrijednostima β parametra

Najvažnije razlog uvođenja nove ε - β distribucije raščlanjenosti ulaznih neizrazitih skupova leži u tome što za vrijednosti slobodnog parametra $\beta > 0$, postoji definirani centroid kod kojeg postoji potpuna pripadnost svim neizrazitim skupovima jedino pri nultoj vrijednosti ulazne varijable (slika 2.7). Centroid se degenerira u nukleus jedino pri nultoj vrijednosti β parametra (slika 2.2). Posljedica ovakvog pristupa je da je funkcija pripadnosti j -te ulazne varijable i -tom neizrazitom skupu A_i^j , dana izrazima (2.30-31) kontinuirana i glatka funkcija sa jednoznačno definiranim vrijednostima viših derivacija na čitavom području $\underline{X}_j \subseteq \mathbb{R}^{p_j}$ razmatranja ulazne varijable. To je čini vrlo pogodnom, za primjenu linearnih i/ili nelinearnih postupaka samoorganiziranja slobodnih parametara **NAR**-a, koji se baziraju na gradijentu njegovih ulaznih varijabli. Kako se kod slijedne regulacije prvenstveno radi o pogreškama malog iznosa, onda se preporuča povećanje gustoće neizrazitih skupova oko radne točke, što ujedno i implicira povećanje osjetljivosti **NAR**-a. Stoga se u ovoj disertaciji usvaja sedam neizrazitih skupova čije su vrijednosti parametara dane u tablici 2.1, a koje u općenitom slučaju ne moraju biti fiksirane.

Broj neizrazitog skupa n_i	Parametar ulaznog neizrazitog skupa ε_i	Baza ulaznog neizrazitog skupa	Centar ulaznog neizrazitog skupa
1	17	2,05	0,0
2	17,2	2,05	0,0
3	19	2,05	0,0
4	21	2,05	0,0
5	31	2,05	0,0
6	65	2,05	0,0
7	122	2,05	0,0

Tablica 2.1 Osnovni parametri ulaznih neizrazitih skupova suvremenog neizrazitog regulatora

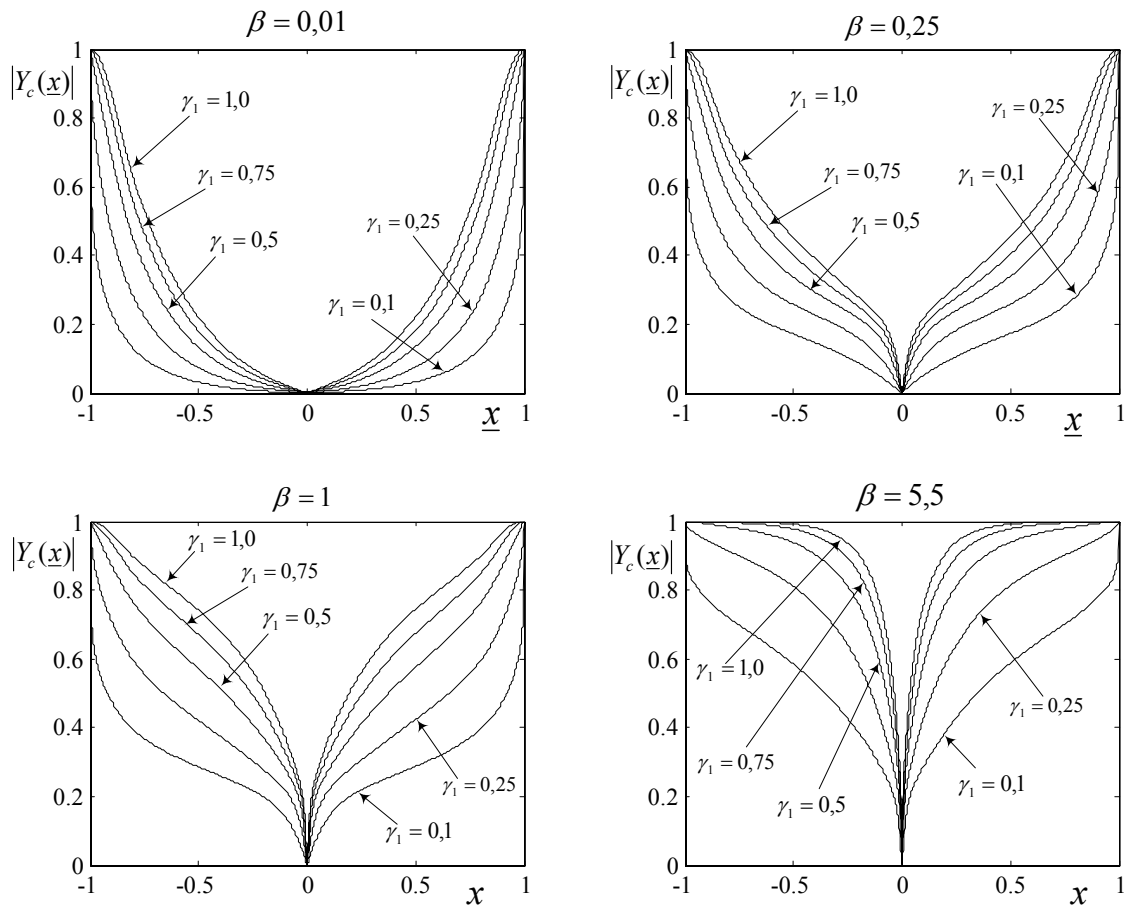
2.4.2 Postupak odlučivanja (inferencije)

S ciljem poboljšanja suvremenog analitičkog pristupa neizrazitoj regulaciji [30,85] umjesto konvencionalnog max-min operatora kompozicije [3] definira se nova aktivacijska funkcija vrlo bliskih karakteristika konvencionalnom max-prod operatoru kompozicije u analitičkom obliku:

$$\omega_j = \left[\underline{S}_1^j(x_j) \right]^{\gamma_1} + \left[\underline{S}_2^j(x_j) \right]^{\gamma_1} + \dots + \left[\underline{S}_{p_j}^j(x_j) \right]^{\gamma_1} = \sum_{i=1}^{p_j} \left[\underline{S}_i^j(x_j) \right]^{\gamma_1}, \quad (2.32)$$

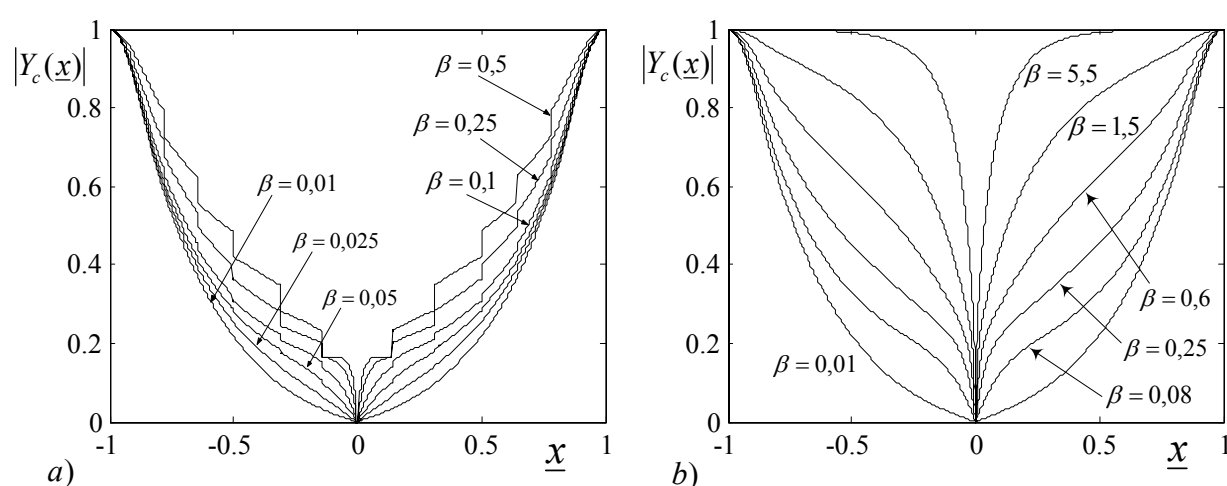
gdje parametar $0 < \gamma_i \leq 1$ predstavlja stupanj pripadnosti j -te ulazne varijable i -tom neizrazitom skupu A_i^j . Za $\gamma_i=1$ kažemo da postoji puni stupanj pripadnosti ulazne varijable i -tom neizrazitom skupu. Da bi se nasuprot konvencionalnom pristupu izbjeglo formiranje baze pravila regulacije, u nastavku daljnjeg izlaganja usvaja se analitička funkcija preslikavanja $f_{cj}(\underline{x}_j)$ dana izrazom (2.23) s kojom se vrši preslikavanje normalizirane ulazne varijable \underline{x}_j na normaliziranu apsolutnu poziciju centra izlaznog neizrazitog skupa \underline{y}_{cj} . U nastavku kao kompenzacija novo uvedenom parametru γ_i , zbog ionako zanemarivog utjecaja, zanemaruje se djelovanje slobodnog parametra α_j na adaptivno pojačanje pozicije izlaznog neizrazitog skupa. Pritom se uz nultu usvojenu vrijednost parametra α_j pozicija izlaznog neizrazitog skupa dobiva na osnovu izraza (2.26) u novom analitičkom obliku:

$$y_{cj} = 2U_m F_j \cdot \left(1 - \frac{\omega_j}{p_j}\right) \cdot \text{sgn}(\underline{x}_j) \quad (2.33)$$



Slika 2.8 Apsolutne vrijednosti normaliziranih pozicija centara izlaznih neizrazitih skupova $|Y_{cj}(x_j)|$, za ε - β distribuciju raščlanjenosti neizrazitih skupova (slika 2.3), pri različitim vrijednostima β i γ parametra

Nasuprot konvencionalnoj teoriji skupova, na osnovu nove uvedene aktivacijske funkcije (2.32) i funkcije preslikavanja ulazne varijable na poziciju centra izlaznog neizrazitog skupa (2.33) proveden je postupak inferencije odnosno odlučivanja u analitičkom obliku. Ovim je izbjegnuto formiranje baze pravila regulacije, a time i eksponencijalni porast neizrazitih pravila regulacije s porastom broja ulaznih varijabli. Utjecaji promjena vrijednosti slobodnog β i γ parametra na već usvojene oblike ulaznih neizrazitih skupova (slika 2.2), grafički su predloženi na (slici 2.8). Kao rezultat preslikavanja ulaznih varijabli $\underline{x}_j \in \underline{X}_j$ sa područja razmatranja $\underline{X}_j \subseteq \mathbb{R}^{p_j}$ na normaliziranu apsolutnu poziciju centra izlaznog neizrazitog skupa dobivaju se točke koje formiraju karakterističnu krivulju. Variranjem slobodnih β i γ parametara dobiva se niz kontinuiranih i derivabilnih karakterističnih krivulja (slika 2.8). Skup karakterističnih krivulja formira karakterističnu površinu. U općenitom slučaju sa stajališta upravljačkog manevarskog djelovanja potrebno je težiti što većoj karakterističnoj površini. Stoga novi predloženi suvremeni analitički pristup neizrazitoj regulaciji u potpunosti opravdava već prije uvedeni prijedlog koji sada postaje geslo poboljšanog analitičkog pristupa neizrazitoj regulaciji, a to je da »dovoljan broj slobodnih parametara neizrazitog regulatora može aproksimirati bilo koju nepoznatu analitičku funkciju«. Dakle uvođenjem novog analitičkog oblika funkcije pripadnosti ulaznom neizrazitom skupu (2.30-31) te njezinom stupnjevanju sa novo uvedenim parametrom γ_l (slika 2.9) postiže se veća iskoristivost karakterističnog područja djelovanja **NAR**-a. U svrhu komparacije sa dosadašnjim analitičkim pristupom karakteristično područje djelovanja **NAR**-a prikazano je na slijedećoj slici.



Slika 2.9 Prikaz karakterističnog područja djelovanja **NAR**-a, za različite vrijednosti parametra β , analitičkim pristupom (2.20-23 i 2.24) a), i poboljšanim suvremenim analitičkim pristupom (2.30-32) b).

2.4.3 Postupak Neizrazito-Decimalne (N/D) pretvorbe

Oblik S_{oj} izlaznog neizrazitog skupa B_j , koji je za j -tu ulaznu varijablu definiran svojom funkcijom pripadnosti S_{B_j} , mijenja se po normaliziranim vremenski diskretnim točkama kako se mijenja ulazna normalizirana varijabla \underline{x}_j . Kako je funkcija pripadnosti S_{B_j} izlaznog neizrazitog skupa B_j dana u zavisnosti od izlazne varijable y , a vrijednost novo uvedene stupnjevine aktivacijske funkcije $(\omega_j)^{\gamma_2}$, ($0 \leq \gamma_2 \leq 1$) mijenja se kako se mijenja ulazna normalizirana varijabla \underline{x}_j , onda je oblik S_{oj} izlaznog neizrazitog skupa B_j funkcija normalizirane vremenski diskretne točke n i izlazne varijable y kako slijedi:

$$S_{oj}(y, n) = [\omega_j(n)]^{\gamma_2} \cdot S_{B_j}(y) . \quad (2.34)$$

U svakoj vremenski diskretnoj točki svaka ulazna vremenski promjenjiva normalizirana varijabla $\underline{x}_j(t)$, aktivira aktivacijskom funkcijom $(\omega_j)^{\gamma_2}$ određenog stupnja djelovanja sebi odgovarajući izlazni neizraziti skup B_j , sa oblikom S_{oj} (2.34). Odavde neposredno slijedi da $(\omega_j)^{\gamma_2}$ djeluje kao težinski faktor na funkciju pripadnosti S_{B_j} izlaznog neizrazitog skupa B_j i time doprinosi promjeni njegovog oblika $S_{oj}(y, n)$ tokom vremena. Kako sa stajališta **MISO**-sustava postoji (m) ulaznih i jedna izlazna varijabla, onda je u svrhu dobivanja kombiniranog oblika izlaznog neizrazitog skupa $S_o(y, n)$ potrebno sumirati oblike izlaznih neizrazitih skupova $S_{oj}(y, n)$ (2.34) dobivenih od svake ulazne normalizirane varijable $\underline{x}_j(n)$ prema izrazu

$$S_o(y, n) = S_{o1}(y, n) + S_{o2}(y, n) + \dots + S_{om}(y, n) = \sum_{j=1}^m S_{oj}(y, n) = \sum_{j=1}^m [\omega_j(n)]^{\gamma_2} \cdot S_{B_j}(y) . \quad (2.35)$$

Ako se u svrhu dobivanja izraza (N/D) pretvorbe u analitičkom obliku ograničimo na jednu normaliziranu vremenski diskretnu točku (n) i fiksiramo je, onda istu u daljnjem razmatranju možemo izostaviti. Nakon definiranja površine I_j ispod krivulje funkcije pripadnosti $S_{B_j}(y)$, j -te ulazne varijable \underline{x}_j izlaznom neizrazitom skupu B_j

$$I_j = \int S_{B_j}(y) dy , \quad (2.36)$$

i definiranja centra y_{cj} izlaznog neizrazitog skupa B_j određenog funkcijom pripadnosti $S_{B_j}(y)$ metodom »momenta površine«

$$y_{cj} = \frac{\int y \cdot S_{B_j}(y) dy}{\int S_{B_j}(y) dy} , \quad (2.37)$$

neposredno slijedi izraz

$$\int y \cdot S_{B_j}(y) dy = y_{cj} I_j . \quad (2.38)$$

Za svaku vrijednost ulazne varijable x_j aktivacijska funkcija određenog stupnja djelovanja $(\omega_j)^{\gamma_2}$ aktivira neizraziti skup B_j , čija se površina oblika uz izraze (2.34 i 2.36) dobiva integralom

$$\int S_{oj}(y) dy = \int (\omega_j)^{\gamma_2} \cdot S_{B_j}(y) dy = (\omega_j)^{\gamma_2} \cdot \int S_{B_j}(y) dy = (\omega_j)^{\gamma_2} I_j , \quad (2.39)$$

dok se uz važeće izraze (2.34 i 2.38), moment površine izlaznog oblika $S_{oj}(y)$ neizrazitog skupa B_j , dobiva integralom oblika:

$$\int y \cdot S_{oj}(y) dy = \int y \cdot (\omega_j)^{\gamma_2} \cdot S_{B_j}(y) dy = (\omega_j)^{\gamma_2} \cdot \int y S_{B_j}(y) dy = (\omega_j)^{\gamma_2} y_{cj} I_j . \quad (2.40)$$

Moment površine kombiniranog oblika $S_o(y)$, izlaznih neizrazitih skupova B_j ($j=1,2,\dots,m$), dobivamo kao ukupno djelovanje pojedinih momenata površine izlaznih oblika $S_{oj}(y)$, aktiviranih od strane (m) ulaznih normaliziranih varijabli neizrazitog regulatora u obliku

$$\int y \cdot S_o(y) dy = \int y \cdot \left(\sum_{j=1}^m S_{oj}(y) \right) dy = \sum_{j=1}^m \int y \cdot S_{oj}(y) dy = \sum_{j=1}^m (\omega_j)^{\gamma_2} y_{cj} I_j . \quad (2.41)$$

Analogno definiranoj površini oblika $S_{oj}(y)$ izlaznog neizrazitog skupa B_j izrazom (2.39), definira se površina kombiniranog oblika $S_o(y)$ (2.35), slijedećim integralom:

$$\int S_o(y) dy = \int \left(\sum_{j=1}^m S_{oj}(y) \right) dy = \sum_{j=1}^m \int S_{oj}(y) dy = \sum_{j=1}^m (\omega_j)^{\gamma_2} I_j . \quad (2.42)$$

(Izoštrena) vrijednost upravljačke varijable u normaliziranoj vremenski diskretnoj točki (n) nakon supstitucije prethodna dva izraza u izraz (2.28), se dobiva u konačnom obliku (prilog 1.):

$$u_F(n+1) = \frac{\sum_{j=1}^m [\omega_j(n)]^{\gamma_2} y_{cj}(n) I_j}{\sum_{j=1}^m [\omega_j(n)]^{\gamma_2} I_j} , \quad (2.43)$$

gdje je vrijednost integrala I_j detaljno izvedena u [40], a ovdje se daje u konačnom obliku

$$I_j = \frac{T_j \cdot (1 + k_j)}{2} . \quad (2.44)$$

Parametar k_j označava faktor pojačanja izlaznog neizrazitog skupa, a jednak je recipročnoj vrijednosti adaptacijskog parametra ε_{oj} , j -tog izlaznog neizrazitog skupa

$$k_j = \frac{1}{\varepsilon_{oj}} . \quad (2.45)$$

Pri vrijednosti $\gamma_2=1$, za aktivacijsku funkciju $\omega_j(n)$ se kaže da je punog stupnja djelovanja i u tom slučaju kao rezultat (**N/D**) pretvorbe dobiva se izraz u analitičkom obliku jednak onome u (2.29). U specijalnom slučaju za relativno male vrijednosti stupnja djelovanja aktivacijske funkcije $\omega_j(n)$ izraz (2.43) se može raspregnuti i predstaviti sumom pozicija centara izlaznih neizrazitih skupova svih j -tih ulaznih varijabli u obliku

$$u_F(n+1) = \frac{1}{m} \sum_{j=1}^m y_{cj}(n) . \quad (2.46)$$

Ako se kod slijednog zadatka regulacije za ulazne varijable usvoje odstupanja po poziciji (e) i brzini (de), onda iz prethodnog izraza neposredno slijedi

$$u_F(n+1) = \psi(e, de, n) = \psi_e(e, n) + \psi_{de}(de, n) , \quad (2.47)$$


gdje $\psi(\cdot)$ općenito označava nelinearnu funkciju svojih varijabli (\cdot). Uz izraz (2.33) nelinearne funkcije pogreške po poziciji ψ_e i brzini ψ_{de} po normaliziranim vremenski diskretnim koracima dobivaju se u obliku

$$\psi_e(e, n) = U_m F_e \cdot \left(1 - \frac{\omega_e(n)}{P_e} \right) \cdot \text{sgn}(e) , \quad \psi_{de}(de, n) = U_m F_{de} \cdot \left(1 - \frac{\omega_{de}(n)}{P_{de}} \right) \cdot \text{sgn}(de) . \quad (2.48)$$

2.5 Analiza utjecaja slobodnog F , β i γ_I parametra preko fazne ravnine stanja


Za različite vrijednosti pogreške pozicije i brzine u svrhu analiziranja utjecaja slobodnih parametara na ponašanje **NAR**-a, prikazane su u faznoj ravnini stanja [72] promjene nivo upravljačkih krivulja sa promjenama vrijednosti pojedinih parametara (slika 2.10-12). Inkrementalni prirast upravljačke varijable između dvije susjedne nivo upravljačke krivulje iznosi $\Delta u_F=0,2$ V, dok je maksimalna normalizirana vrijednost upravljačke varijable $U/U_m=1$. Zato gustoća prikaza nivo upravljačkih krivulja govori o vrijednostima statičkog pojačanja u pojedinim točkama fazne ravnine stanja. Različite točke u ravnini stanja dobivene su za različite vrijednosti pogreške pozicije i brzine. Prijeklopnicom se naziva, nivo upravljačku krivulju nulte vrijednosti. Nagib prijeklopnice u odnosu na horizontalu govori o odnosu statičkog pojačanja brzine i pozicije. Analiza slobodnih parametara u ravnini stanja provedena je pri nagibu prijeklopnice od 45° prema horizontali, što znači pri jednakim iznosima statičkog pojačanja pozicije i brzine u neposrednoj blizini prijeklopnice.

Pri usvojenoj nultoj vrijednosti slobodnog parametra β i punom stupnju pripadnosti pogreške pozicije i brzine ulaznim neizrazitim skupovima iz faznih ravnina stanja prikazanih na slici 2.10 očigledno je da se porastom vrijednosti parametra F povećava i gustoća nivo upravljačkih krivulja oko prijeklopnice, što za posljedicu ima općenito povećanje statičkog pojačanja. Osim porasta vrijednosti statičkog pojačanja što neposredno slijedi i iz izraza (2.47), općenito s povećanjem F parametra povećava se i područje zasićenja, što se vidi iz veće strmine upravljačke površine u blizini prijeklopnice. U manjem središnjem dijelu ravnine stanja pri povećanju relativno malih iznosa pogreške pozicije i brzine dolazi do povećanja gustoće nivo upravljačkih krivulja što rezultira povećanim vrijednostima statičkog pojačanja. Pri konstantnoj vrijednosti svih ostalih parametara smanjenjem γ_1 parametra utječe se na smanjenje područja zasićenja u ravnini stanja i općenito na smanjenje nelinearnosti. Pri tome kod manjih vrijednosti pogreške pozicije i relativno većih vrijednosti pogreške brzine **NAR** se ponaša kao nelinearni proporcionalni regulator po poziciji, dok pri manjim vrijednostima pogreške brzine i većim vrijednostima pogreške pozicije **NAR** ima izraženo derivacijsko djelovanje (slika 2.10).



Slika 2.10 Prikaz nelinearnih nivo upravljačkih krivulja $u_F = \Psi(e, de) = \text{const}$, za $\Delta u_F = 0,2$ i $\beta = 0$ te različitim vrijednostima slobodnog F i γ_1 parametra.


Općenito s povećanjem β parametra pri punom stupnju pripadnosti pogreške pozicije i brzine ulaznim neizrazitim skupovima, mijenja se oblik nivo upravljačkih krivulja u faznoj ravnini stanja. Pri vrijednosti slobodnog parametra $\beta=0,035$ u većem dijelu ravnine stanja postoji približno linearno djelovanje **NAR**-a, sa prisutnim nelinearnostima pri većim iznosima pogreške pozicije i brzine (slika 2.11). U tom slučaju **NAR** se ponaša približno kao linearni **PD** ili **PI** regulator. Pri sagledavanju rada **NAR**-a kao nelinearnog **PI** regulatora umjesto **PD**-regulatora razlika je jedino u tome što nivo upravljačke krivulje u faznim ravninama stanja predstavljaju prirast upravljačke varijable. Detaljnija razmatranja vezana za ovo predviđena su u trećem i petom poglavlju. Smanjenjem stupnja pripadnosti pogreške pozicije i brzine ulaznim neizrazitim skupovima, povećavaju se nelinearnosti u čitavoj ravnini stanja. Za vrijednost parametra $\gamma_1=0,1$ pri povećanju pogreške pozicije i brzine povećavaju se vrijednosti statičkog pojačanja što rezultira povećanom gustoćom nivo upravljačkih krivulja na rubovima prijeklopnice (slika 2.11).



Slika 2.11 Prikaz nelinearnih nivo upravljačkih krivulja $u_F = \Psi(e, de) = \text{const}$, za $\Delta u_F=0,2$ i $\beta=0,035$ te različitim vrijednostima slobodnog F i γ_1 parametra.

Povećanjem β parametra iznad vrijednosti 0,035 pri punom stupnju pripadnosti pogreške pozicije i brzine ulaznim neizrazitim skupovima dolaze do izražaja nelinearna svojstva **NAR**-a. Za $\beta=0,1$ na prikazanim ravninama stanja (slika 2.12), vidi se da kako idemo od središta prema

rubovima prijeklopnice nivo upravljačke krivulje divergiraju odnosno vrijednosti statičkih pojačanja se kontinuirano smanjuju. Za relativno malo središnje područje fazne ravnine stanja pri malim iznosima pogreške pozicije i brzine vrijedi da se s povećanjem pogreške smanjuje gustoća nivo upravljačkih krivulja odnosno vrijednosti statičkih pojačanja, što je suprotno djelovanju **NAR**-a dano ravninama stanja na slici 2.10. Smanjenjem stupnja pripadnosti pogreške pozicije i brzine ulaznim neizrazitim skupovima nelinearnosti se smanjuju gdje pri $\gamma_1=0,1$ postoji linearno djelovanje u širem središnjem dijelu fazne ravnine stanja. Kako se ide prema rubovima prijeklopnice gustoća nivo upravljačkih krivulja se povećava što rezultira kontinuiranim povećanjem vrijednosti statičkog pojačanja. Nivo upravljačke krivulje konvergiraju ka rubovima prijeklopnice (slika 2.12). Dakle djelovanje **NAR**-a za veće vrijednosti pogreške pozicije i brzine je suprotno djelovanju **NAR**-u pri graničnom vrijednosti β parametra i punog stupnja pripadnosti pogreške pozicije i brzine ulaznim neizrazitim skupovima (slika 2.11).



Slika 2.12 Prikaz nelinearnih nivo upravljačkih krivulja $u_F = \Psi(e, de) = \text{const}$, za $\Delta u_F=0,2$ i $\beta=0,1$ te različitim vrijednostima slobodnog F i γ_1 parametra.

Promjenom F , β i γ_1 parametra, nivo upravljačke krivulje mogu poprimiti bilo koji oblik u faznoj ravnini stanja. Za određene vrijednosti pogreške pozicije i brzine pravilnim izborom F , β i γ_1 parametra može se realizirati upravljačka trajektorija bilo kojeg oblika. Upravo ta važeća

činjenica osnova je novog poboljšanog suvremenog analitičkog pristupa neizrazitoj regulaciji, gdje će se u daljnjem izlaganju dosadašnji naziv **NAR**, s opravdanim razlogom zamijeniti nazivom **Poboljšani Neizraziti Analitički Regulator (PNAR)**.

2.6 Stupanj neizrazitog djelovanja η poboljšanog neizrazitog analitičkog regulatora

U radu [38,40] pokazano je da je napon motora kao upravljačka varijabla i-tog servosustava mobilnog robota jednaka

$$(u_m)_i = \frac{(J_m N^2 + h_{ii})R}{C_M} \ddot{q}_i + (C_E + \frac{D_m N^2 R}{C_M}) \dot{q}_i + \frac{h_{ij} R}{C_M} \ddot{q}_j, \quad i \neq j \quad i = 1, 2. \quad (2.49)$$

Parametri iz prethodnog izraza imaju slijedeće značenje: h_{ii} , h_{ij} i $J_m N^2$ (kgm²) redom predstavljaju vlastiti, unakrsni moment tromosti mehanizma mobilnog robota te armaturni moment tromosti istosmjernog motora sveden na izlazno vratilo reduktora, dok R (Ω) označava otpor armature. Zatim se davaju konstante proporcionalnosti elektromotorne sile C_E (Vs/rad), momenta C_M (Nm/A) i koeficijenta viskoznog trenja $D_m N^2$ (Nms/rad), svedene na izlazno vratilo reduktora čiji redukcijски omjer od izlaza do ulaza reduktora je N . Kako se u najčešćem slučaju gibanje mobilnog robota linearnim dijelom zadane referentne putanje odvija konstantnom nazivnom brzinom $(v_c)_n$, onda pri takvom stacionarnom, ustaljenom gibanju mobilnog robota potrebno je na ulaze servomotora osigurati napon konstantnog iznosa $(u_m)_n$. Do istog se dolazi uz kutne brzine lijevog i desnog pogonskog kotača jednakog nazivnog iznosa $(\dot{q}_i)_n$ iz prethodnog izraza ispuštanjem pribrojnika koji opisuju dinamiku višeg reda

$$(u_m)_n = (C_E + \frac{D_m N^2 R}{C_m}) \frac{(v_c)_n}{r}. \quad (2.50)$$

Ovdje r (m), označava polumjer pogonskih kotača. Napon $(u_m)_n$ na ulazu servomotora ostvaruje se upravljačkim naponom $(u_r)_n$ preko naponskog pojačala snage pojačanja K_{Pu} . Stoga se prethodni izraz zapisuje u obliku

$$(u_r)_n = (C_E + \frac{D_m N^2 R}{C_m}) \frac{(v_c)_n}{K_{Pu} r}. \quad (2.51)$$

Pri stacionarnom gibanju mobilnog robota postoji jedino pogreška po položaju, tako da se zatvaranjem povratne veze po poziciji i brzini za upravljački napon dobiva

$$(u_r)_n = -K_p (q - q_n) = -K_p \Delta q. \quad (2.52)$$

Izjednačavanjem prethodna dva izraza, dolazi se u prostoru unutarnjih upravljanih koordinata do nominalne pogreške položaja u obliku

$$(\Delta q)_n = -(C_E + \frac{D_m N^2 R}{C_m}) \frac{(v_e)_n}{K_P K_{Pu} r} , \quad (2.53)$$

gdje negativan predznak govori o kašnjenju upravljane varijable (q), u odnosu na željenu (nominalnu) vrijednost (q_n). Zakon upravljanja, realiziran klasičnim (konvencionalnim) **Proporcionalno-Derivacijskim (PD)** regulatorom dan izrazom

$$u_r = -K_p(q - q_n) - K_v(\dot{q} - \dot{q}_n) = -K_p \Delta q - K_v \Delta \dot{q} , \quad (2.54)$$

u kojem K_P i K_V označavaju pojačanja po položaju i brzini, zamjenjujemo kod suvremenog pristupa neizrazitoj regulaciji s **PD-PNAR**-om općenitog oblika

$$u_F = \Psi(e, de, \varepsilon, \alpha, F, \beta, T, k) = \phi_1(e, de)Y_e(e) + \phi_2(e, de)Y_{de}(de) , \quad (2.55)$$

gdje $\Psi(e, de, \varepsilon, \alpha, F, \beta, T, k)$, označava nelinearnu funkciju neizrazite upravljačke varijable o pogrešci pozicije (e), brzine (de) i ostalih slobodnih parametara koji se mogu mijenjati. Pritom je s ϕ_i označena i -ta neizrazita težinska funkcija, koja pri punom aktivacijskom djelovanju iznosi

$$\phi_i(e, de, T, k) = \frac{\omega_i T_i (1 + k_i)}{\sum_{j=1}^m \omega_j T_j (1 + k_j)} , \quad i, j=1, 2 . \quad (2.56)$$


Pri stacionarnom (ustaljenom) gibanju mobilnog robota po pravcu, definirani nulti položaji centara izlaznih neizrazitih skupova brzine $Y_{de}(de)$, **PNAR**-a lijevog i desnog pogonskog kotača su nepromijenjeni. Stoga u tom slučaju nominalna vrijednost upravljačke varijable napona, nelinearna je funkcija jedino položaja centara izlaznih neizrazitih skupova pozicije, te kod slobodnih parametara fiksnih vrijednosti, izraz (2.55) poprima oblik identičan onom u (2.48), dobivenom aktivacijskom funkcijom zanemarivog stupnja djelovanja tj. vrijedi

$$(u_F)_n = \psi_e(e) = Y_e(e) . \quad (2.57)$$

Suvremenim analitičkim pristupom neizrazitoj regulaciji iz prethodnog izraza i izraza (2.52) dolazi se do kvocijenta neizrazite upravljačke varijable $(u_r)_n = (u_F)_n$ i nominalne vrijednosti pogreške položaja $(\Delta q)_n = -e_n$, koja je također kao i neizrazita upravljačka varijabla, pri ustaljenom gibanju mobilnog robota po pravcu konstantnog iznosa. Kako taj kvocijent ima karakter pojačanja, onda on u stacionarnom režimu rada dobiva naziv statičkog nominalnog pojačanja K_n

$$K_n = \frac{(u_F)_n}{e_n} = \frac{\Psi_e(e_n)}{e_n} = \frac{Y_e(e_n)}{e_n} . \quad (2.58)$$

Općenito kod **SISO** sustava nominalnom vrijednosti pogreške (e_n) i neizrazite upravljačke varijable $u_F = Y_e(e)$, definirana je statička radna točka T (slika 2.12a). Teorijski kroz jednu statičku radnu točku moguće je povući beskonačni broj nelinearnih zavisnosti neizrazite upravljačke varijable $\Psi_e(e)$ o pogreški (e). Ta familija krivulja određena je njezinim zajedničkim svojstvom, a to je da je vrijednost statičkog pojačanja K_n u radnoj točki konstantnog iznosa, pa se ono uzima i kao identifikacijski parametar te familije nelinearnih zavisnosti. Sa (slike 2.13a) može se zaključiti o prvom osnovnom svojstvu neizrazitog analitičkog regulatora: pri određenoj nelinearnoj zavisnosti $u_F = \Psi_e(e)$ svakoj ulaznoj vrijednosti pogreške (e) jednoznačno se pridružuje vrijednost upravljačke veličine (u_F) što znači da je kod suvremenog analitičkog pristupa neizrazitoj regulaciji isključeno histerežno djelovanje.



Slika 2.13. Grafovi karakterističnih krivulja (2.57) a) i prirasta upravljačke varijable Δu_F u statičkoj radnoj točki $T(e_n, (u_F)_n)$, progresivne-a ($F=1,64 \beta=0$), linearne-b ($F=0,49 \beta=0,033$) i degresivne-c ($F=0,15 \beta=2,29$) karakteristične krivulje b) pri $U_m=15V$

Kod **NAR**-a sa jednim ulazom i jednim izlazom ta je nelinearna zavisnost opisana karakterističnom krivuljom, dok se u općenitom slučaju kod (m) ulaznih veličina formira (m)-dimenzionalna karakteristična upravljačka površina, zadržavajući i dalje osnovno svojstvo da se pri točno određenoj (m)-torki ulaznih varijabli formira točno određena vrijednost izlazne neizrazite upravljačke varijable. Npr. kod **PD-PNAR**-a kao slijednog regulatora, različite kombinacije uređenih parova (e, de) pogreške pozicije $e \in \{-e_{\min} \dots e_{\max}\}$ i brzine $de \in \{-de_{\min} \dots de_{\max}\}$ dovode do niza vrijednosti neizrazite upravljačke varijable koje zajedno formiraju upravljačku plohu $u_F = \Psi(e, de, \varepsilon^*, \alpha^*, F^*, \beta^*, T^*, k^*)$. Ovdje kao i kod neizrazitog analitičkog regulatora s jednim ulazom mora pri projektiranju biti zadovoljen i drugi osnovni uvjet a to je da nulte pogreške pozicije i brzine dovode do nulte upravljačke varijable što se može zaključiti iz prikazanih karakterističnih krivulja (slika 2.13). Slobodni parametri označeni s zvjezdicom ukazuju na njihovu odabranu fiksnu vrijednost u fazi projektiranja poboljšanog neizrazitog analitičkog regulatora, te u nastavku izlaganja gdje to slučaj zahtijeva, isti se u zapisu

moгу izostaviti. Da bi iz familije karakterističnih krivulja (slika 2.13a) određenih parametrom $K_n = \text{const}$, identificirali odnosno izdvojili točno određenu upravljačku krivulju $u_F = \Psi(e)$ potrebno je definirati parametar, kao osnovno svojstvo određene karakteristične krivulje $u_F = \Psi(e)$ izdvojene iz familije nelinearnih zavisnosti određenih parametrom $K_n = \text{const}$. Taj novi parametar predstavljen je stupnjem neizrazitog djelovanja regulatora (η). Za zadanu ulaznu pogrešku neizrazito djelovanje položaja centra izlaznog neizrazitog skupa $Y_e(e)$, ogleda se u promijeni položaja u odnosu na položaj koji bi imao centar neizrazitog skupa određen linearnom karakterističnom krivuljom (slika 2.13a). Kako se ovom doktorskom disertacijom projektira slijedni samoorganizirajući **NAR** sa mjerenim malim vrijednostima pogreške onda je od više mogućnosti, odabran onaj pri kojem se stupanj neizrazitog djelovanja definira pri stotom dijelu nominalne pogreške $e_n = (\Delta q)_n$ (2.53). Stoga definicioni izraz stupnja neizrazitog djelovanja **PNAR**-a glasi

$$\eta = \frac{\Psi(0.01e_n) - K_n(0.01e_n)}{K_n(0.01e_n)} . \quad (2.59)$$

Pri nultom stupnju neizrazitog djelovanja u svojoj osnovi nelinearni **NAR** se svojim djelovanjem maksimalno približio konvencionalnom linearnom regulatoru o čemu govori i izdvojena linearna karakteristična krivulja (*b*) na slici 2.13. Upravo nulti stupanj neizrazitog djelovanja govori o graničnom slučaju u radu **NAR**-a. O tome govori i zakon superpozicije koji vrijedi za linearne sustave.

$$\psi(e_1) + \psi(e_2) = \psi(e_1 + e_2) . \quad (2.60)$$

Zakon superpozicije realizacijom karakterističnih krivulja (*a*) i (*c*) ne vrijedi jer iste opisuju izrazito nelinearne zavisnosti neizrazite upravljačke varijable $u_F = Y_e(e)$ o pogrešci. Ako npr. redom definiramo pogreške pozicije $e_1 = 0.05$ i $e_2 = 0.15$ onda primjenom zakona neizrazitog analitičkog upravljanja danih nelinearnim karakterističnim krivuljama (*a*, *b* i *c*) se dobivaju redom slijedeće zavisnosti

$$\psi(0,05) + \psi(0,15) = 0,481 + 1,466 = 1,947 \approx \psi(0,2) = 1,991 , \quad (2.61)$$

$$\psi(0,05) + \psi(0,15) = 0,0291 + 0,8152 = 0,8443 < \psi(0,2) = 1,6762 , \quad (2.62)$$

$$\psi(0,05) + \psi(0,15) = 1,767 + 2,222 = 3,989 > \psi(0,2) = 2,258 . \quad (2.63)$$

Prva zavisnost (2.61) izražava približno linearno djelovanje **NAR**-a, dok druge dvije zavisnosti (2.62-63) predstavljaju njegovo izrazito nelinearno djelovanje. Ako pri zadanim pogreškama

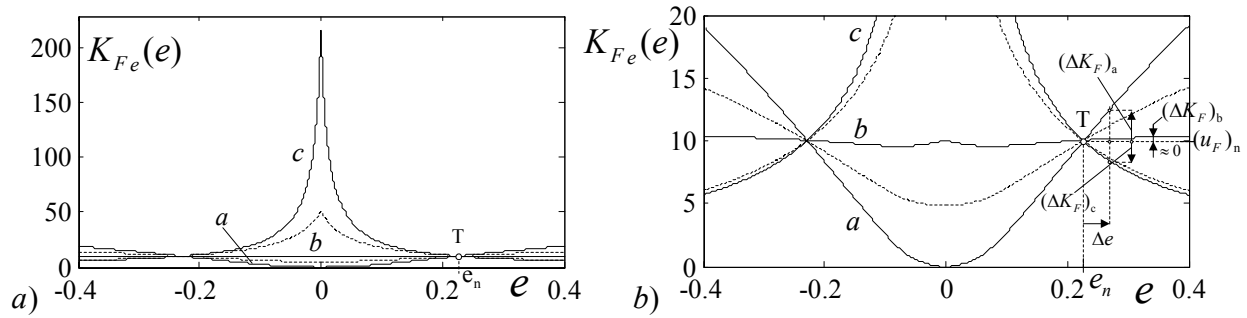
vrijedi $e < e_n$, onda je vrijednost neizrazite upravljačke varijable manja od vrijednosti koju bi imao pri linearnoj karakterističnoj krivulji (b) (slika 2.13), izraz (2.61), i u tom slučaju je **PNAR** u progresivnom modu rada (karakteristična krivulja (a) na slici 2.13), izraz (2.62), za razliku od degresivnog moda (karakteristična krivulja (c) na slici 2.13), i izraza (2.63), gdje je vrijednost neizrazite upravljačke varijable redovito veće vrijednosti nego pri nultom stupnju neizrazitog djelovanja regulatora ($\eta=0$). Ovisno o modu rada kod suvremenog analitičkog pristupa neizrazitoj regulaciji razlikuju se dvije međusobno različite klase **PNAR**-a o čemu ovisi i njihova primjena te daljnji pravac razvoja. Kod prve klase neizrazitog analitičkog regulatora, sa progresivnim modom rada, pozitivnom prirastu pogreške u statičkoj radnoj točki (Δe) odgovara znatno veći pozitivni prirast upravljačke varijable $(\Delta u_F)_a$, u odnosu na prirast $(\Delta u_F)_b$ pri linearnom režimu rada, dok je kod druge klase poboljšanog neizrazitog analitičkog regulatora sa izraženim degresivnim modom rada taj prirast mnogo manji gotovo zanemarivi $(\Delta u_F)_c \approx 0$ u odnosu na ostale režime rada. Stoga **NAR** prve klase radi sa stupnjem neizrazitog djelovanja (2.59) manjim od nule ($\eta < 0$), za razliku od degresivnog moda rada neizrazitog analitičkog regulatora gdje je stupanj neizrazitog djelovanja veći od nule ($\eta > 0$). Na temelju svega do sada rečenog definira se pojam dinamičkog pojačanja K_{Fd} **PNAR**-a u okolini statičke radne točke

$$K_{Fd} = \frac{\Delta u_F}{\Delta e} = \frac{\Delta \psi(e)}{\Delta e} , \quad (2.64)$$

na osnovu kojeg se dolazi do spoznaje da u okolini statičke radne točke pri progresivnom modu rada postoji dinamičko pojačanje $K_{Fd} > K_n$, a u degresivnom modu rada da vrijedi $K_{Fd} < K_n$ što predstavlja osnovne značajke prve i druge klase **PNAR**-a pri čemu su isti i dobili takav naziv. Jedino pri nultom stupnju neizrazitog djelovanja ($\eta=0$), **NAR**-a dinamičko pojačanje (K_{Fd}) približno je jednako statičkom nominalnom pojačanju (K_n), što je zbog približno linearne prirode karakterističnih krivulja sasvim razumljivo. Kvocijent neizrazite upravljačke varijable i pogreške dan izrazom (2.58) poprima konstantnu vrijednost K_n jedino kod familije karakterističnih krivulja sa zajedničkim svojstvom da sve prolaze statičkom radnom točkom ($e=e_n$), dok se omjer tih veličina kod svih ostalih pogreški $e \neq e_n$, pri degresivnom ($\eta > 0$) i progresivnom ($\eta < 0$) modu rada znatno razlikuju i fizikalno predstavljaju statičko pojačanje. Stoga se u čisto matematičkom formalnom smislu izraz (2.58), odnosno (2.57) zapisuje u općenito prihvatljivijem obliku

$$u_F = \Psi_e(e) = Y_e(e) = K_{Fe}(e)e , \quad (2.65)$$

gdje K_{Fe} predstavlja nelinearno statičko pojačanje **PNAR**-a.



Slika 2.14 Prikaz familije nelinearnih zavisnosti statičkog pojačanja $K_{Fe}(e)$ o pogrešci **a)**, te prirasta statičkog Pojačanja ΔK_F u statičkoj radnoj točki $T(e_n, (u_F)_n)$ **b)**, za različite karakteristične krivulje prikazane na (slici 2.12).

Za različite vrijednosti stupnja neizrazitog djelovanja i pogreški poboljšanog neizrazitog analitičkog regulatora dolazi se do funkcionalne zavisnosti nelinearnog statičkog pojačanja s pogreškom (slika 2.14). Na slici 2.14b vidi se da pri pozitivnom prirastu pogreške u statičkoj radnoj točki pri progresivnom modu rada ($\eta < 0$) odgovara pozitivni prirast neizrazitog pojačanja $(\Delta K_{Fe})_a$, odnosno negativan prirast $(\Delta K_{Fe})_c$ pri degresivnom modu rada ($\eta > 0$), odnosno do promjene zanemarivog iznosa $(\Delta K_{Fe})_c \approx 0$ pri linearnom režimu rada **PNAR**-a. Može se zato općenito zaključiti da s porastom pogreške kod prve klase neizrazitog analitičkog regulatora dolazi do porasta, a kod druge klase poboljšanog neizrazitog analitičkog regulatora do smanjenja statičkog nelinearnog pojačanja. U pogledu definiranog neizrazitog nelinearnog pojačanja $K_{Fe}(e)$, kvocijent upravljačke varijable i nulte vrijednosti pogreške $e=0$ predstavlja singularnost tipa neodređenog oblika. U graničnom slučaju puštanjem limesa s lijeve i desne strane da teži nultoj vrijednosti pogreške dolazi se i kod tog slučaja do definirane vrijednosti nelinearnog pojačanja

$$K_{Fe}(e=0) = \lim_{e \rightarrow \pm 0} \left(\frac{Y_e}{e} \right) = \left(\frac{\partial Y_e(e)}{\partial e} \right)_{e=0} = \left(\frac{\partial u_F}{\partial e} \right)_{e=0} = (\Theta_e)_{e=0}, \quad (2.66)$$

kao osjetljivosti izlazne upravljačke varijable pri nultoj vrijednosti ulazne pogreške. S obzirom na sve do sada rečeno razvija se primjena i daljnji razvoj neizrazitih analitičkih regulatora u dva smjera:

- Razvoj **Poboljšanog Neizrazitog Analitičkog Regulatora (PNAR-a)** u smislu očuvanja asimptotske stabilnosti reguliranog sustava. Ovom smjeru pripada prva klasa analitičkih regulatora ($\eta < 0$) (slika 3.3), s osnovnom karakteristikom da općeniti porast pogreške (e) dovodi do progresivnog porasta neizrazitog pojačanja (K_{Fe}), pri čemu vrijedi da je $\text{sgn}(\Delta e) = \text{sgn}(\Delta K_{Fe})$.

- Drugi smjer razvoja **PNAR**-a, nastao je uslijed njegove dualne prirode s prvim smjerom razvoja, a ide u smislu zadržanja eksponencijalne i/ili praktične stabilnosti **Objekta Regulacije (OR)**. Ovom smjeru pripada druga klasa analitičkih regulatora ($\eta > 0$) (slika 3.4), kod kojih porast pogreške dovodi do degresivnog smanjenja vrijednosti **Neizrazitog Pojačanja (NP)**, pri čemu vrijedi $\text{sgn}(\Delta e) = -\text{sgn}(\Delta K_{Fe})$, (slika 2.14).

Iako je nelinearna karakteristična krivulja koja pripada familiji karakterističnih krivulja opisanih zajedničkim parametrom $K_n = \text{const}$, s definiranjem dodatnog parametra stupnja neizrazitog djelovanja (η) izrazom (2.59) sada jednoznačno određena, nameće se pitanje pri kojim je vrijednostima slobodnih parametara **PNAR**-a to moguće ostvariti. Iz izraza (2.55) (koji pokazuje općenitu zavisnost neizrazite upravljačke varijable slijednog **PNAR**-a kako o pogreškama pozicije i brzine tako i o slobodnim parametrima) može se zaključiti u teorijskom smislu da različite strukture **PNAR**-a mogu osigurati zadani stupanj neizrazitog djelovanja (η) pri $K_n = \text{const}$. Zbog višeznačnosti mogućeg rješenja provedena je analiza utjecaja pojedinih slobodnih parametara na formiranje upravljačke plohe, koja je pokazala da promjena parametra α analitičke funkcije $Y_e(e)$ za izračunavanje položaja centra izlaznog neizrazitog skupa ulazne pogreške (e) nema većeg utjecaja na poboljšanje karakteristika pri formiranju upravljačke plohe. Zato se u daljnjem razmatranju uzima da je $\alpha = 0$. Utjecaj parametra baze (T) i adaptacijskog pojačanja (k) izlaznog neizrazitog skupa pripadajuće ulazne varijable također je zanemarivo malog utjecaja na kvalitetu formiranja upravljačke plohe. Kod slijednog **PD-PNAR**-a, u [40] pokazalo se je da promjena parametara T i k poboljšava karakteristike formirane upravljačke plohe na jednom dijelu dok ih na drugom dijelu istovremeno narušava. Stoga nije moguće istovremeno osigurati podjednako zadovoljavajuće upravljačko djelovanje po poziciji i brzini. Zato je preporuka da se pri projektiranju slijednih **PNAR**-a ovi parametri uzimaju jednakih konstantnih vrijednosti za svaku ulaznu varijablu posebno npr. $T_e = T_{de} = 0.5$, $k_e = k_{de} = 0.75$. Ovim se osigurava podjednako zadovoljavajuće neizrazito upravljačko djelovanje i po poziciji i po brzini. Osnovni parametri izlaznih neizrazitih skupova korišteni u ovoj disertaciji dani su u (tablici 2.2). Adaptacijski parametri ε_i $i=1,2,\dots,n_m$, ulaznih neizrazitih skupova, gdje je n_m broj neizrazitih skupova m -te ulazne varijable, odabiru se u početnoj fazi projektiranja **PNAR**-a i drže konstantnim vrijednostima. Preporuka je da kod slijedne regulacije bude veća gustoća ulaznih neizrazitih skupova oko radne točke odnosno nultih vrijednosti ulaznih pogreški (tablica 2.1).

Parametri	1. SSG robota (rotacija)	2. SSG robota (rotacija)
T_e, T_{de}	0,5	0,5
α_e, α_{de}	0	0
k_e, k_{de}	0,75	0,75
$\gamma_{1e}, \gamma_{1de}$	0,96	0,96
$\gamma_{2e}, \gamma_{2de}$	0,03	0,03
U_m	15	15

Tablica 2.2 Osnovni parametri izlaznih neizrazitih skupova suvremenog neizrazitog regulatora

Neizrazito upravljačko djelovanje **PNAR**-a, pri stacionarnom gibanju mobilnog robota pravocrtnim dijelovima referentne trajektorije zapisuje se u obliku

$$u_F = \Psi(e, \varepsilon^*, \alpha^*, F, \beta, T^*, k^*) , \quad (2.67)$$

gdje su zvjezdicom označene fiksne vrijednosti parametara. Sa uređenim parovima slobodnih parametara (F, β) međusobno različitih vrijednosti, moguće je realizirati bilo koju karakterističnu krivulju iz familije $K_n = \text{const}$ prikazane na slici 2.14. Položaj centra izlaznog neizrazitog skupa dan analitičkom funkcijom Y_e , osim ulazne pogreške položaja zavisi i o parametru pojačanja analitičke funkcije F i parametru raspodjele ulaznih neizrazitih skupova β . Stoga se prethodni izraz zapisuje u prikladnijem obliku

$$u_F = \Psi(e, F, \beta) = Y_e(e, F, \beta) . \quad (2.68)$$

Kako je familija karakterističnih krivulja određena parametrom K_n , kod kojeg vrijedi da je za nominalnu vrijednost pogreške po položaju $e = e_n$, vrijednost neizrazite upravljačke varijable jednaka $u_F = (u_F)_n = (u_r)_n$, onda prethodni izraz nelinearne zavisnosti zapisan eksplicitnom formom zamjenjujemo izrazom nelinearne zavisnosti parametra β o parametru F , implicitnom formom oblika

$$\Psi_F(e_n, F, \beta, u_{F_n}) = Y_e(e, F, \beta) - (u_F)_n = 0 , \quad (2.69)$$

gdje Ψ_F predstavlja implicitnu nelinearnu funkcionalnu zavisnost F i β parametra. Za poznatu fiksnu početnu vrijednost parametra raspodjele ulaznih neizrazitih skupova β_o^* , možemo Tejlorovim razvojem prethodno zadane implicitne funkcije u okolišu približnog rješenja F_i doći do izraza.

$$\Psi_F(e_n, F_i + \Delta F_i, \beta_o^*, u_{F_n}) = \Psi_F(e_n, F_i, \beta_o^*, u_{F_n}) + \frac{\partial \Psi_F(e_n, F_i, \beta_o^*, u_{F_n})}{\partial F_i} \Delta F_i . \quad (2.70)$$

Kako je za točno rješenje ($F^* = F_o$) vrijednost Tejlorovog razvoja u okolišu približnog rješenja ($\Delta F_i = F^* - F_i$) jednako nuli, onda uz definiranu parcijalnu derivaciju

$$\frac{\partial \Psi_F(e_n, F_i, \beta_o^*, u_{F_n})}{\partial F_i} = \frac{\partial Y_e(e_n, F_i, \beta_o^*)}{\partial F_i} = \Theta_{F_i}, \quad (2.71)$$

i izraze (2.69-70) dolazi se do točnijeg rješenja $F_i = F_{i+1}$ početnog parametra $F_o = F_i$ u obliku

$$F_{i+1} = F_i + \Theta_{F_i}^{-1}[(u_F)_n - Y_e(e_n, F_i, \beta_o^*)], \quad i=0,1,\dots \quad (2.72)$$


Pritom $\Theta_{F_i}^{-1}$ predstavlja inverznu funkciju osjetljivosti neizrazite upravljačke varijable o parametru F_i , do koje dolazimo izrazom (2.71) u obliku:

$$\Theta_{F_i} = U_m \operatorname{sgn}(e) \underline{Y}_e(e) \quad (2.73)$$

Izrazom (2.72) dana je iteracijska metoda, kod koje brzina konvergencije ka točnom rješenju F^* prvenstveno ovisi o početnom odabiru vrijednosti parametra F . Ako početnu vrijednost parametra F označimo sa F_o^* , onda je nužan i dovoljan uvjet konvergencije iteracijskog postupka (2.72) ka točnom rješenju F^* da vrijedi

$$\operatorname{sgn}[Y_e(e_n, F_o^*, \beta_o^*)] = \operatorname{sgn}\left[\frac{\partial^2 Y_e(e_n, F, \beta_o^*)}{\partial^2 F}\right]_{F=F_o^*} = \operatorname{sgn}\left[\frac{\partial \Theta_F}{\partial F}\right]_{F=F_o^*} \quad (2.74)$$

Pošto je izrazom (2.72) zapravo definirana jednadžba tangente, onda se metoda određivanja točnog rješenja F^* parametra F , pri zadanoj početnoj vrijednosti parametra β_o^* zorno grafički prikazuje preko niza tangenti na slici 2.15.



Slika 2.15 Grafički prikaz rada rekursivnog algoritma (2.72) pri bijektivnom određivanju međusobne zavisnosti F^* i β^* parametra pri nelinearnoj funkciji $(u_F)_n = Y_e(e_n, F, \beta)$.

Svim vrijednostima β parametra iz skupa vrijednosti $\beta \in \{\beta_{\min} \dots \beta_{\max}\}$ pridružuju se bijektivnom u principu nelinearnom funkcijom odnosno danim iteracijskim postupkom (2.72) vrijednosti F parametra $F \in \{F_{\max} \dots F_{\min}\}$, pri čemu vrijedi da se najmanjem elementu iz skupa β bijekcijom pridružuje najveći element iz skupa F i obrnuto. Kako po definiciji parametri β i F pripadaju skupu pozitivnih realnih vrijednosti, onda je za minimalnu vrijednost β parametra usvojeno da je $\beta_{\min}=0$, dok se minimalna vrijednost F parametra određuje iz apsolutne pozicije centra $|Y_e(e)| = |\psi_e(e)|$ izlaznog neizrazitog skupa (2.48) uz uvjet da je $u_F = (u_F)_n$. Pritom se uzima da je normalizirana pozicija izlaznog neizrazitog skupa jednaka jedinici $\underline{Y}_e(e) = 1$, što znači da je ista uzeta pri najmanjem odstupanju ulazne varijable, odnosno pri najmanje mogućoj vrijednosti aktivacijske funkcije ω_e

$$F_{\min} = \frac{(u_F)_n}{U_m}, \quad (2.75)$$

gdje U_m označava maksimalno moguću vrijednost upravljačke varijable u_F . To je zato jer **PNAR**, pri ustaljenom gibanju mobilnog robota mora minimalno osigurati vrijednost upravljačke varijable u_F određene naponom u statičkoj radnoj točki $(u_F)_n$. Maksimalna vrijednost F parametra F_{\max} dobiva se iteracijskom metodom (1.24) za $\beta_o = \beta_{\min} = 0$. Isto tako maksimalna vrijednost β parametra β_{\max} dobiva se iteracijskom metodom tangenti iz izraza analognom izrazu (2.72) uz početnu minimalnu vrijednost F parametra F_{\min} dan prethodnim izrazom:

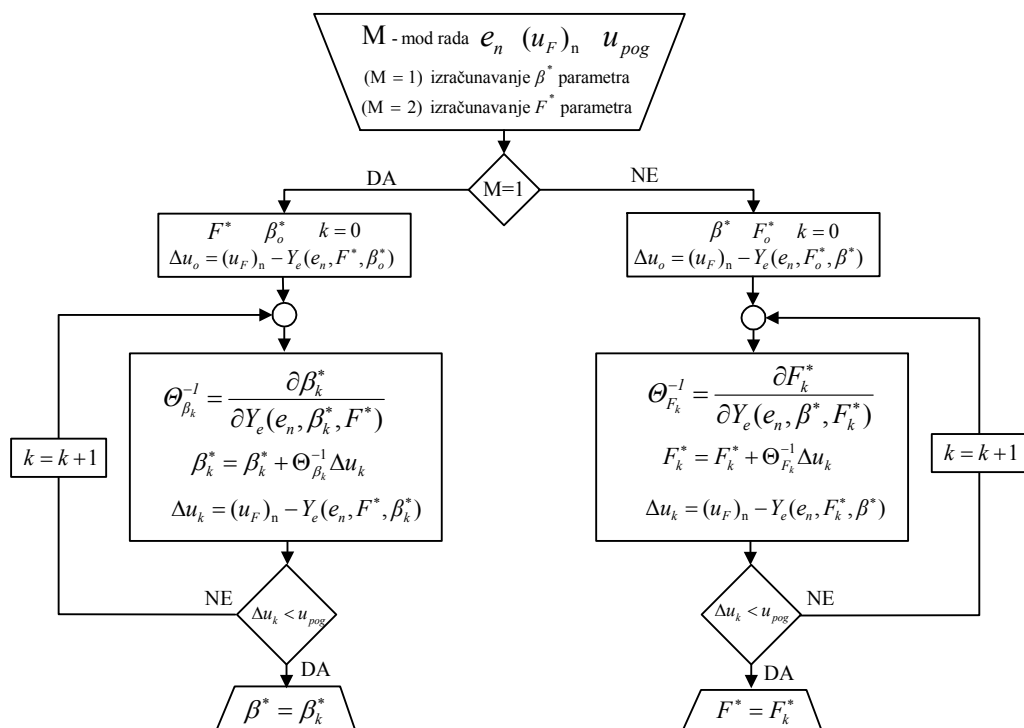
$$\beta_{i+1} = \beta_i + \Theta_{\beta_i}^{-1}[(u_F)_n - Y_e(e_n, F_{\min}, \beta_i)] \quad i=1, 2, \dots, \quad (2.76)$$

gdje je $\Theta_{\beta_i}^{-1}$ inverzna funkcija osjetljivosti neizrazite upravljačke varijable o β_i parametru, do koje dolazimo izrazom

$$\Theta_{\beta_i} = \frac{\partial \Psi_F(e_n, \beta_i, F_o^*, u_{Fn})}{\partial \beta_i} = \frac{\partial Y_e(e_n, \beta_i, F_o^*)}{\partial \beta_i} = -U_m \operatorname{sgn}(e) \frac{1}{n_e} \sum_{i=1}^{n_e} \frac{\varepsilon_i |e|}{\exp(\beta_i \varepsilon_i |e|)} S_i(e), \quad (2.77)$$

gdje $S_i(e)$ označava funkciju pripadnosti koja odgovara i -tom ulaznom neizrazitom skupu normalizirane ulazne pogreške (e) . Na (slici 2.16) prikazan je blok dijagram algoritma programske podrške pri određivanju F i β parametra na elektroničkom računalu, a izvorni kod programa u tehničkom okruženju programskog paketa **MATLAB** – (**MAT**rični – **LAB**oratorij) pod nazivom *odrFB.m* dan je u prilogu 2 na kraju disertacije. Osjetljivosti Θ_F (2.73) i Θ_β (2.77) upravljačke varijable $u_F(e)$ o slobodnim parametrima F i β predstavljaju jednu od važnih osobina **PNAR**-a pri razumijevanju njegovog rada. Za određeni prirast upravljačke varijable, pri većim

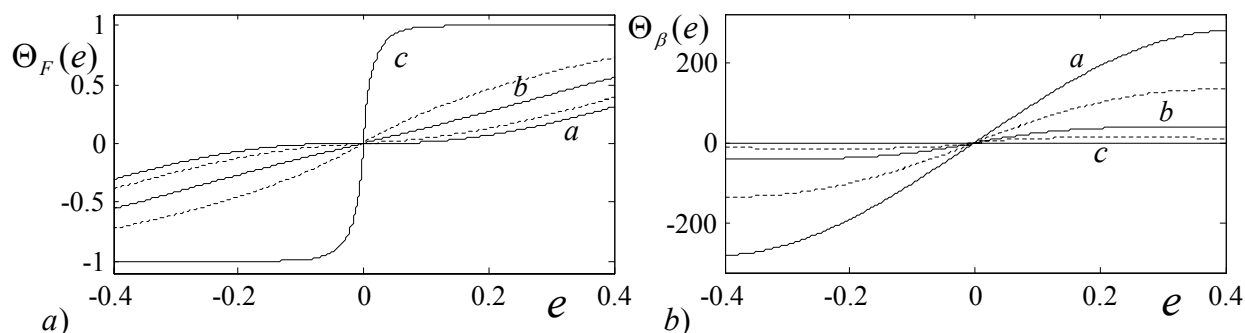
vrijednostima osjetljivosti o parametru, biti će potrebna manja promjena vrijednosti parametra i obrnuto, što na neki način implicira vezu i sa stabilnosti sustava.



Slika 2.16 Blok dijagram algoritma programske realizacije pri određivanju općenito nelinearne bijekcijske funkcionalne zavisnosti između F i β parametra.

Da bi pri stacionarnim uvjetima slijedni dinamički sustav bio stabilan, teži se da nastali poremećaji pri slijeđenju referentne trajektorije u vidu pogreške pozicije i brzine budu kompenzirani minimalnom promjenom pojedinih parametara. To je zbog toga što promjena parametra pri kojemu je osjetljivost upravljačke varijable veća, izaziva i veću promjenu iste što može biti nedopustivo sa stajališta očuvanja praktične stabilnosti dinamičkog sustava. Iz tog razloga, promjena upravljačke varijable o pojedinom parametru često se naziva i gradijentom upravljačke veličine po tom parametru. Na slici 2.17, prikazane su osjetljivosti (gradijenti) upravljačke varijable o F i β parametru. Iz dijagrama na slici 2.17a, može se zaključiti da općenito povećanje F parametra pri familiji karakterističnih krivulja $K_n = \text{const}$ (Slika 2.13) dovodi do smanjenja gradijenta upravljačke varijable po F parametru. To znači da će određena promjena F parametra rezultirati znatno većom promjenom upravljačke varijable u regresivnom nego u progresivnom modu rada **PNAR**-a. Također se iz nelinearnih funkcijskih zavisnosti osjetljivosti Θ_β upravljačke varijable o β parametru dane slikom 2.17b, zaključuje da smanjenje

vrijednosti β parametra, istovremeno dovodi do povećanja osjetljivosti upravljačke veličine na taj parametar.



Slika 2.17 Prikaz nelinearnih funkcija osjetljivosti upravljačke varijable o F i β parametru, a) $\Theta_F(e)$ i b) $\Theta_\beta(e)$, za karakteristične krivulje prikazane na (slici 2.13).

Stoga je za određeni prirast β parametra, gradijent upravljačke veličine veći u progresivnom nego u degresivnom modu rada **PNAR**-a. U degresivnom modu rada pri većim vrijednostima pogreške dolazi do zasićenja u pogledu osjetljivosti upravljačke veličine o F parametru, dok je osjetljivost upravljačke veličine na β parametar zanemarivo malog iznosa za gotovo sve vrijednosti pogreške. Promjenu upravljačke veličine određenog iznosa je stoga u degresivnom modu rada moguće osigurati s dosta manjom promjenom F parametra nego s promjenom β parametra. S druge strane kod progresivnog moda rada zahtjevana promjena upravljačke veličine ostvaruje se s daleko manjom promjenom β parametra nego F parametra. Iz prikazanih funkcija osjetljivosti slijedi važna osobina **PNAR**-a, da su karakteristične krivulje (slika 2.12), kontinuirane (neprekidne) i derivabilne funkcije parametara i pogreške bez mogućih diskontinuiranosti. Kod slijednog dinamičkog sustava mobilnog robota s utvrđenim astatizmom prvog reda postoji pri nagibnoj pobudi na ulazu pogreška po položaju. Pri stacionarnom (ustaljenom) gibanju to je nominalna vrijednost pogreške e_n , koja zajedno s neizrazito upravljačkom varijablom napona $(u_F)_n$ definira statičku radnu točku T na dijagramima prikazanim slikama 2.13-14. Ovako definiranje statičke radne točke na nekom dijelu karakteristične ravnine imaju niz nedostataka od kojih se navode najvažniji:

- Zbog važećih vrijednosti $\Delta e > 0 \Rightarrow \Delta u_F > 0 \quad \Delta K_F > 0$,
 $\Delta e < 0 \Rightarrow \Delta u_F < 0 \quad \Delta K_F < 0$,

pri progresivnom modu rada svako odstupanje od referentne trajektorije neće biti tretirano na isti način. Pri pozitivnim prirastima pogreške osiguran je zbog $\Delta K_F > 0$ povećani stupanj

asimptotske stabilnosti sustava, dok negativan prirast pogreške $\Delta K_F < 0$ narušava ASimptotsku Stabilnost (AS) sustava, dok je kod degresivnog moda rada situacija suprotna od navedene.

- Ograničena gotovo nemoguća primjena degresivnog moda rada zbog ulaska neizrazite upravljačke varijable u područje zasićenja, odnosno područje relativno malih promjena upravljačke varijable Δu_F i nelinearnog pojačanja ΔK_F pri prirastima pogreške pri većim vrijednostima nominalne pogreške (slike 2.13-14).
- Neosjetljivost ili vrlo mala osjetljivost gotovo konstantnog iznosa upravljačke varijable na promjene β parametra pri većim vrijednostima pogreške, što naročito dolazi do izražaja pri većem stupnju neizrazitog djelovanja ($\eta < 0$) (slika 2.17b). Također pri relativno većim pogreškama i većim vrijednostima stupnja neizrazitog djelovanja ($\eta < 0$) vrijedi da je osjetljivost upravljačke veličine o F parametru gotovo konstantne vrijednosti (slika 2.17a).

Prvom od navedenih nedostataka se može doskočiti preklapanjem karakterističnih krivulja, gdje bi pri pogreškama $e < e_n$ odnosno kod negativnog prirasta pogreške $\Delta e < 0$, bio osiguran degresivni mod, a pri pozitivnim prirastima pogreške $\Delta e > 0$ progresivan mod rada **PNAR**-a. Na taj način bi svaki prirast pogreške od nominalne vrijednosti $\Delta e \neq 0$ imao za posljedicu prirast statičkog nelinearnog pojačanja ΔK_{Fe} a samim tim bi se osigurao i povećani stupanj asimptotske stabilnosti sustava. Navedeno rješenje bi imalo smisla samo za male iznose prirasta pogreške oko nominalne vrijednosti e_n , jer bi za veće vrijednosti negativnog prirasta pogreške za koje vrijedi $|\Delta e| > e_n$, došlo do ponovog narušavanja postojeće AS sustava. To je zbog toga jer je karakteristična krivulja simetrična s obzirom na nultu vrijednost pogreške, odnosno neparna je funkcija pogreške jer vrijedi

$$Y_e(-e, F, \beta) = -Y_e(e, F, \beta) . \quad (2.78)$$

Zbog ograničenosti na male priraste pogreške oko nominalne vrijednosti i prirasti pojačanja ΔK_{Fe} će biti relativno manjih iznosa što neće znatnije utjecati na AS sustava. Zbog navedenih nedostataka, a koji su jednim dijelom vezani i za osjetljivost upravljačke varijable na F i β parametar, te zbog same složenosti izvedbe preklapanja upravljačkih krivulja, pristupa se traženju novog rješenja. Dosadašnje proučavanje osnovnih karakteristika familije karakterističnih krivulja, pokazalo je da se najveće promjene kako upravljačke varijable Δu_F (slika 2.13), tako i statičkog nelinearnog pojačanja ΔK_F (slika 2.14), kao i promjene osjetljivosti upravljačke varijable $\Delta \Theta_F$ i $\Delta \Theta_\beta$ (slika 2.16), javljaju pri malim vrijednostima pogreške u okolini nultog iznosa pogreške. Stoga je osnovna ideja u pomicanju radne točke u ishodište

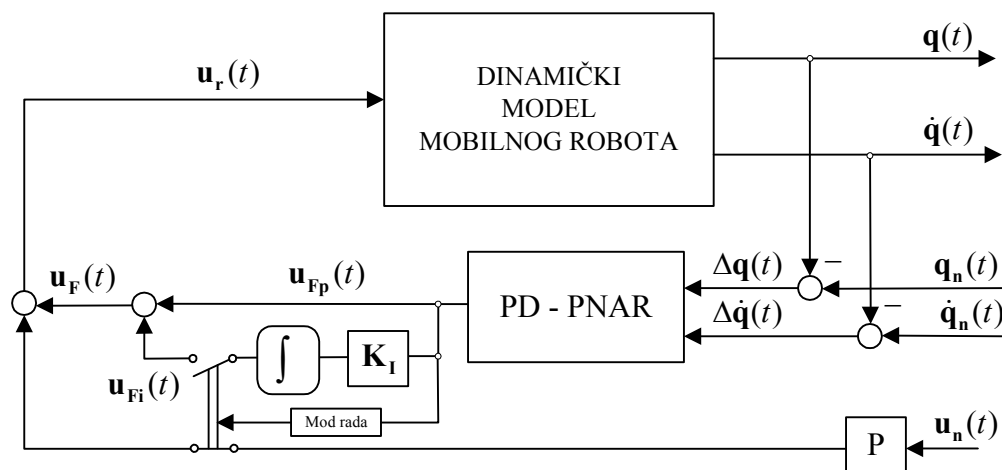
karakteristične ravnine, što je moguće jedino eliminiranjem na neki način stacionarne nominalne pogreške po položaju. To se može realizirati na jedan od dva moguća načina:

- Dodavanjem integralnog člana u svrhu eliminiranja statičke pogreške, (mod rada $M=1$),
- Uvođenjem predupravljanja ili unaprijednog djelovanja (eng. *feedforward*), (mod rada $M=0$).

Ukupno upravljanje $u_r(t)$ u tom slučaju bilo bi jednako

$$u_r(t) = \Psi(e, de, F, \beta, t) + (1 - M)Pu_n(t) + MK_I \int \Psi(e, de, F, \beta, t) dt, \quad (2.79)$$

gdje P i K_I redom predstavljaju pojačanje predupravljanja i integralnog djelovanja. Ovim rješenjem dolazi do izražaja neizrazito djelovanje **PNAR**-a, gdje prirast pogreške pri progresivnom modu rada ima za posljedicu znatan prirast položaja centra izlaznih neizrazitih skupova ulaznih varijabli, odnosno prirast nelinearnog pojačanja K_{Fe} u smislu povećanja **AS OR**. Na slici 2.18 prikazana je realizacija zakona upravljanja dana izrazom (2.79). Za ovakvu zadanu strukturu **PNAR**-a potrebno je pronaći algoritam samoorganiziranja njegovih parametara F i β u smislu formiranja karakteristične upravljačke plohe, a s ciljem povećanja stupnja **AS** s prirastom odstupanja položaja i brzine od ravnotežnog, ustaljenog gibanja mobilnog robota.



Slika 2.18 Struktura **PNAR**-a pri vođenju mobilnog robota unaprijed zadanom referentnom trajektorijom u prostoru unutarnjih upravljanih koordinata.

Iz svega do sada iznesenog proizlaze osnovne karakteristike poboljšanog neizrazitog analitičkog regulatora **PNAR**-a:


-
1. Nelinearnost karakteristične krivulje, koja svakoj ulaznoj varijabli (pogrešci) bijekcijom pridružuje vrijednost izlazne upravljačke varijable $u_F = \Psi_e(e)$.
 2. Karakteristična krivulja, kao podskup mogućeg rješenja u karakterističnoj ravnini je glatka kontinuirana i derivabilna funkcija ulaznih varijabli.
 3. Karakteristična krivulja je neparna funkcija ulazne varijable $Y_e(-e, F, \beta) = -Y_e(e, F, \beta)$
 4. Nulte vrijednosti ulaznih varijabli pridružuju nultu vrijednost izlazne upravljačke varijable.
 5. U graničnom slučaju za nultu vrijednost ulazne varijable statičko pojačanje **PNAR**-a jednako je osjetljivosti upravljačke varijable $Y_e(e)$.
 6. Najveće promjene kako upravljačke veličine, tako i statičkog pojačanja i funkcija osjetljivosti jesu u okolini nulte vrijednosti pogreške.
 7. Zbog izostale vremenske dinamike, karakteristična krivulja spada u grupu statičkih nelinearnih krivulja što doprinosi vremenskoj invarijantnosti **PNAR**-a i po tim svojstvima ga približava regulatoru u prostoru stanja.

3. POČETNO PODEŠAVANJE POBOLJŠANOG NEIZRAZITOG ANALITIČKOG REGULATORA

Pod početnim podešavanjem podrazumijeva se dovođenje **PNAR**-a u stanje minimalne pobuđenosti. Upravljačka karakteristična površina $u_F = \Psi(e, de, F, \beta)$ ima stanje minimalne pobuđenosti jedino u graničnom slučaju, kad se **PNAR** u svom radu maksimalno približio karakteristikama linearnog regulatora. Osnovna bit u nastavku izloženog postupka je izoliranje dvije upravljačke krivulje $\psi_e(e, F, \beta)$ i $\psi_{de}(de, F, \beta)$ (2.48). One bi jednoznačno iz karakterističnog prostora selektirale karakterističnu površinu s osnovnim svojstvom da vrijednosti parcijalnih derivacija po ulaznim varijablama pogrešci položaja i brzine budu približno jednake za sve moguće vrijednosti pogreške pozicije $e \in \{e_{\min}, \dots, e_{\max}\}$ i brzine $de \in \{de_{\min}, \dots, de_{\max}\}$ tj. da približno vrijedi


$$\frac{\partial \psi(e, de, F, \beta)}{\partial e} \approx K_{Fe} \approx \text{const} \quad , \quad \frac{\partial \psi(e, de, F, \beta)}{\partial de} \approx K_{Fde} \approx \text{const} \quad , \quad (3.1)$$

Pokazalo se je da prethodni izraz približno vrijedi za sve vrijednosti pogreške pozicije i brzine iz fazne ravnine stanja određene skupom mogućih vrijednosti $e \in \{e_{\min}, \dots, e_{\max}\}$, $de \in \{de_{\min}, \dots, de_{\max}\}$. To znači da je **PNAR** u stanju minimalne pobuđenosti u kojem slučaju vrijedi da je osjetljivost upravljačke varijable po položaju Θ_e i brzini Θ_{de} približno jednaka vrijednostima statičkog pojačanja po položaju K_{Fe} i brzini K_{Fde} . U tom graničnom slučaju rada **PNAR**-a dinamička je vrijednost pojačanja po položaju i brzini približno jednaka svojim statičkim vrijednostima. Izoliranje karakterističnih krivulja za koje vrijedi prethodni izraz išlo bi u smjeru izdvajanja karakterističnih krivulja nultog stupnja neizrazitog djelovanja ($\eta=0$) iz familije karakterističnih krivulja, određenih njihovim zajedničkim parametrom $K_n = \text{const}$. U postupku početnog ugađanja **PNAR**-a, zajedničke parametre K_n familijama karakterističnih krivulja, izjednačavamo s faktorima pojačanja linearnog zakona upravljanja (2.54). Pritom se do nominalne vrijednosti upravljačkog napona $(u_F)_n$ pri stacionarnom gibanju u prostoru unutarnjih upravljanih koordinata, s konstantnom kutnom brzinom (\dot{q}_n) , dolazi ispuštanjem članova diferencijalne jednadžbe s dinamikom višeg reda, a nominalna podešena vrijednost pogreške izračunava se izrazom (2.58). Pri točno određenom paru F i β parametara moguće je iz familije karakterističnih krivulja $K_n = \text{const}$ izdvojiti onu karakterističnu krivulju sa svojstvom nultog neizrazitog djelovanja (2.59). Zato je za određenu vrijednost parametra $K_n = \text{const}$, prikazana dijagramom na slici 3.1 zavisnost stupnja neizrazitog djelovanja o β parametru.



Slika 3.1 Prikaz nelinearne zavisnosti $\eta(\beta)$, za sljedeće vrijednosti parametara $K_n=1$ $\beta_a=0.0105$ (a), $K_n=10$ $\beta_b=0.033$ (b) i $K_n=50$ $\beta_c=0.0165$ (c).

Kod zajedničkog parametra familije karakterističnih krivulja $K_n=10$, na slici 3.1 s β parametrom vrijednosti $\beta_b=0.033$ označen je nulti stupanj neizrazitog djelovanja **PNAR**-a. Kod vrijednosti $\beta < \beta_b$ radi se o progresivnom ($\eta < 0$), a pri $\beta > \beta_b$ degresivnom modu rada ($\eta > 0$) **PNAR**-a. Za različite vrijednosti parametra K_n nelinearne zavisnosti $\eta(\beta)$, imaju zajedničko svojstvo da je stupanj neizrazitog djelovanja **PNAR**-a kod nulte vrijednosti β parametra jednako -1. Iz izraza (2.59) se može zaključiti da je to jedino moguće pri nultoj vrijednosti upravljačke varijable, a koja je moguća jedino pri nultim vrijednostima svih ulaznih varijabli **PNAR**-a. **NAR** za nultu vrijednost β parametra i nulte vrijednosti ulaznih varijabli posjeduje karakteristično svojstvo da je vrijednost nelinearnog statičkog pojačanja jednako nuli (slika 2.13b). Pri opsegu relativno manjih vrijednosti K_n parametra, s porastom parametra kod nultog neizrazitog djelovanja povećava se vrijednost β parametra, dok se pri većim rastućim vrijednostima K_n parametra, do nultog stupnja neizrazitog djelovanja ($\eta=0$) dolazi kod sve manjih vrijednosti β parametra. Ta u biti nelinearna zavisnost dana je sljedećim dijagramom na slici 3.2.

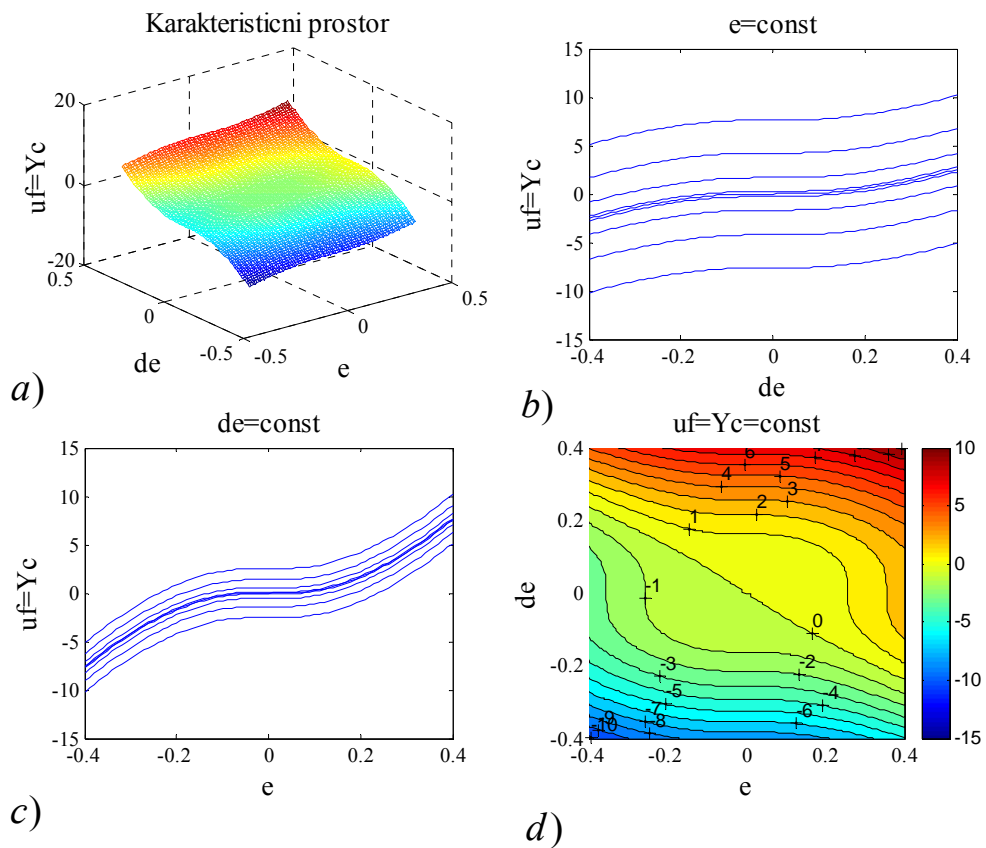


Slika 3.2 Prikaz nelinearne funkcijske zavisnosti $\beta(F)$, pri nultom stupnju neizrazitog djelovanja ($\eta=0$) za različite vrijednosti rastućeg parametra K_n .

Nelinearna zavisnost $\beta(F)$ dijeli ravninu stanja β - F parametra na dva dijela. Uređeni parovi (β, F) određeni nelinearnom zavisnosti $\beta(F)$, pri nultom stupnju neizrazitog djelovanja ($\eta=0$) dobivaju se pri različitim vrijednostima parametra K_n . Iz dijagrama na (slici 3.2) vidljivo je ograničenje u pogledu minimalne vrijednosti F parametra. Njegova minimalna vrijednost F_{min} određena je izrazom (2.75) i ovisi o naponu držanja $(u_F)_n$ potrebnim za stacionarno gibanje mobilnog robota konstantnom nominalnom brzinom pravocrtnim dijelom referentne putanje. Zbog toga ravninu stanja β - F parametra, za vrijednosti parametra $K_n < (u_F)_n$, je s donje strane ograničena pravcem $F_{min} = \text{const}$ (2.75). Za odabrane vrijednosti parametara

$$F_e = 1,644; \quad \beta_e = 0,00; \quad F_{de} = 0,544; \quad \beta_{de} = 0,00; \quad U_m = 15V \quad (3.2)$$

struktura **PNAR**-a (2.47), pripada prvoj klasi regulatora. Neizrazito djelovanje **PNAR**-a, je određeno superpozicijom karakterističnih krivulja $\psi_e(e, F_e, \beta_e)$ i $\psi_{de}(de, F_{de}, \beta_{de})$ (2.48), čiji parametri (3.2) su tako odabrani da osiguravaju u potpunosti progresivni mod rada **PNAR**-a.

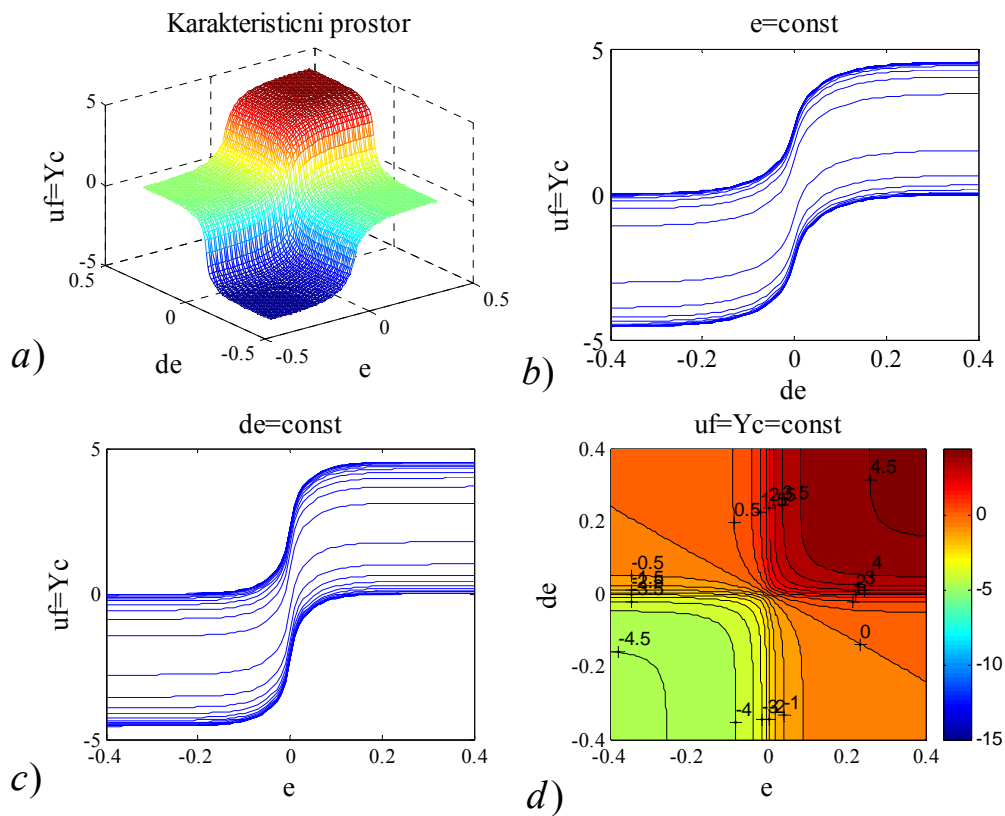


Slika 3.3 a) Prikaz karakterističnog neizrazitog prostora prve klase **PNAR** (3.2), karakterističnih krivulja u progresivnom modu rada b) $u_F = \psi(e^*, de)$; c) $u_F = \psi(e, de^*)$ i nivo upravljačkih krivulja d) $\Psi(e, de, F^*, \beta^*) = \text{const}$ u faznoj ravnini stanja.

Uređeni parovi parametara (β, F) karakterističnih krivulja, kao i par (β_l, F_l) prikazan na slici 3.2, nalaze se u donjem djelu β - F ravnine ograničenom nelinearnom zavisnosti $\beta(F)$ za koju općenito vrijedi $\eta < 0$. Karakterističan neizraziti prostor, kao i karakteristične krivulje koje osiguravaju progresivni mod rada **PNAR**-a prikazane su na (slici 3.3). Karakteristične krivulje (2.48) odabranih parametara

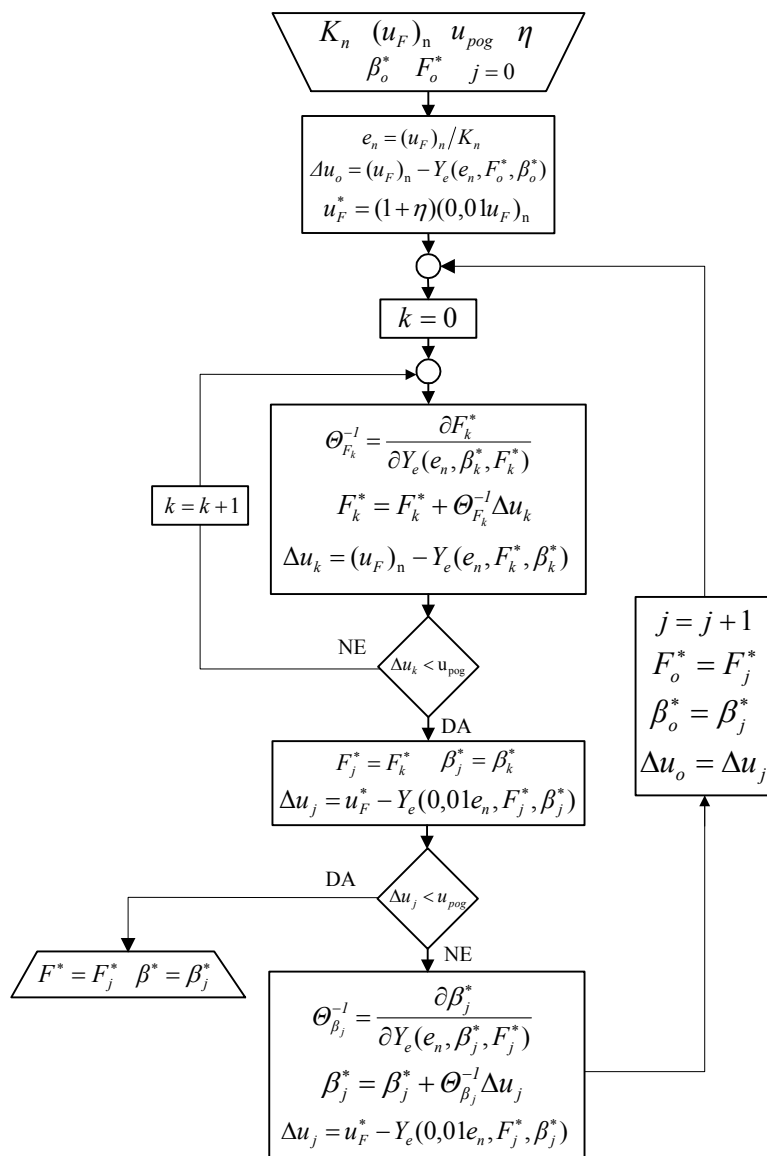
$$F_e = 0,152; \quad \beta_e = 1,155; \quad F_{de} = 0,152; \quad \beta_{de} = 0,661; \quad U_m = 15V \quad (3.3)$$

osiguravaju u potpunosti degresivni mod rada **PNAR**-a (2.47). U ovom slučaju **PNAR** pripada drugoj klasi **NAR**-a čija struktura je određena parovima parametara (β_e, F_e) i (β_{de}, F_{de}) usvojenih izrazom (3.3) koji se kao i par (β_2, F_2) nalaze u gornjem dijelu β - F ravnine prikazanom na slici 3.2 u kojoj vrijedi $\eta > 0$. Na slici 3.4 prikazan je tipičan primjer karakterističnog neizrazitog prostora druge klase **NAR**-a zajedno s karakterističnim krivuljama koje u potpunosti osiguravaju njegov degresivni mod rada.



Slika 3.4 a) Prikaz karakterističnog neizrazitog prostora druge klase **PNAR**(3.3), karakterističnih krivulja u degresivnom modu rada b) $u_F = \psi(e^*, de)$; c) $u_F = \psi(e, de^*)$ i nivo upravljačkih krivulja d) $\Psi(e, de, F^*, \beta^*) = \text{const}$ u faznoj ravnini stanja.

Snimanje nelinearne zavisnosti $\beta(F)$ pri nultom stupnju neizrazitog djelovanja ($\eta=0$) za različite vrijednosti parametra K_n (slika 3.2), realizira se programskom podrškom u tehničkom okruženju programskog paketa **MATLAB**.



Slika 3.5 Blok dijagram algoritma programske podrške pri početnom podešavanju **PNAR-a**.

Na slici 3.5 prikazan je blok dijagram algoritma za izračunavanje F i β parametara pri početnom podešavanju (ugađanju) **PNAR**-a, za zadanu vrijednost parametra K_n i nominalnog napona $(u_F)_n$. Izlistani program pod nazivom *ppdFB.m* je dan u prilogu 3 na kraju disertacije. Ponavljanjem algoritma za zadani nominalni napon $(u_F)_n$ pri različitim vrijednostima parametra K_n dolazi se do uređenih parova parametara (β, F) koji predstavljaju snimljenu karakteristiku danu na slici 3.2.

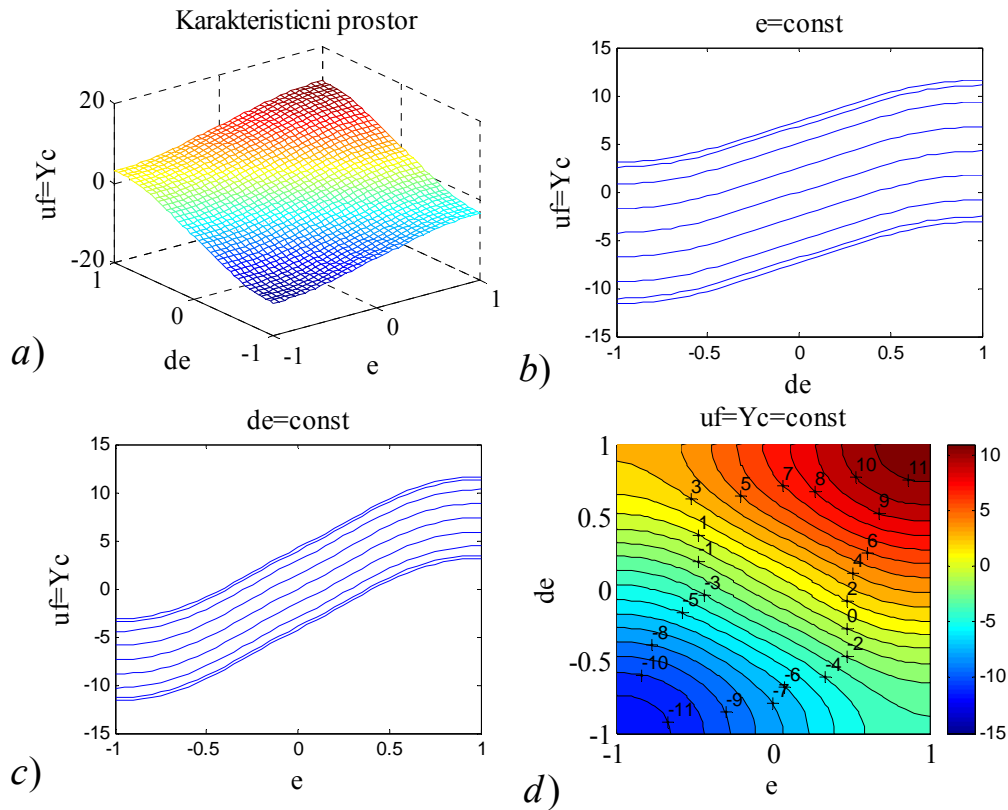
Tom nelinearnom karakteristikom prikazani su parovi F i β parametara kao rezultati početnog ugađanja **PNAR**-a za različite vrijednosti parametra K_n . Dani algoritam za početno ugađanje ($\eta=0$) prikazan blok dijagramom na slici 3.3 može se koristiti za ugađanje, bilo kojeg stupnja neizrazitog djelovanja **PNAR**-a jednostavnim zadavanjem vrijednosti (η), na početku programa. Pri početnom ugađanju slijednog **PD-PNAR**-a zapisanog u općenitom obliku

$$u_F = \Psi(e, de, F, \beta) = \phi_1(e, de)Y_e(e, F_e, \beta_e) + \phi_2(e, de)Y_{de}(de, F_{de}, \beta_{de}) , \quad (3.4)$$

uz nominalno potrebni upravljački napon ustaljenog gibanja mobilnog robota $(u_F)_n=2,277$ V i unaprijed definirane zahtjevane parametre položaja $K_{np}=10$ i brzine $K_{nv}=6$, primjenom danog algoritma (slika 3.5), odnosno prethodno izloženim postupkom (slika 3.2), uz $U_m=15$ V dolazi se redom do parametara karakterističnih krivulja pozicije $Y_e(e, F_e, \beta_e)$ i brzine $Y_{de}(de, F_{de}, \beta_{de})$.

$$F_e=0,491; \quad \beta_e=0,033; \quad F_{de}=0,283; \quad \beta_{de}=0,034. \quad (3.5)$$

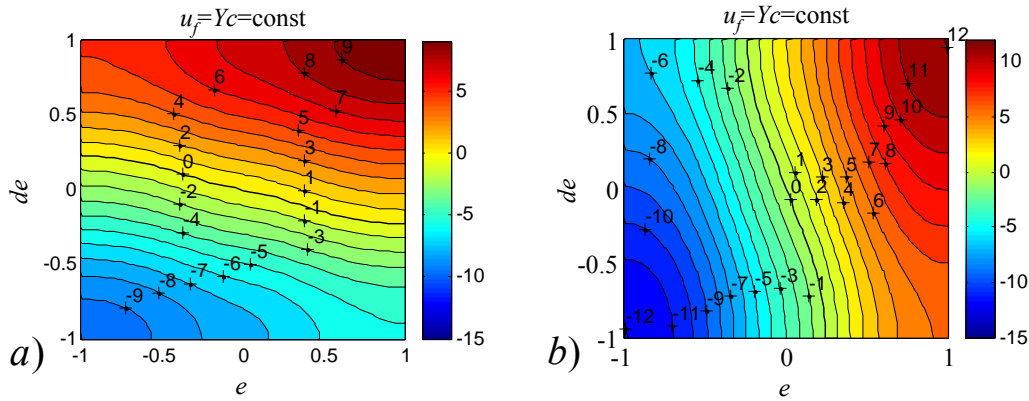
Za navedene vrijednosti na slici 3.6a prikazan je karakteristični neizraziti prostor **PNAR**-a.



Slika 3.6 a) Prikaz karakterističnog neizrazitog prostora ugađenog **PNAR**-a; karakterističnih krivulja b) $u_F = \psi(e^*, de)$; c) $u_F = \psi(e, de^*)$ i nivo upravljačkih krivulja d) $\Psi(e, de, F^*, \beta^*) = \text{const}$ u faznoj ravni pri $(u_F)_n=2,277$ V i $K_{np}=10$ i $K_{nv}=6$

Radi se o gotovo ravnoj upravljačkoj ravnini koso položenoj, čiji nagib prema osama pogreške položaja i brzine je približno jednak statičkim vrijednostima pojačanja danim izrazom (3.1). Za ekvidistantne vrijednosti pogreške položaja dolazi se do karakterističnih krivulja $e=\text{const}$, odnosno nelinearnih zakonitosti $u_F = \psi(e^*, de)$, (slika 3.6b) čiji su nagibi prema horizontali za male vrijednosti pogreške položaja približno jednaki statičkom pojačanju pogreške po brzini $K_{Fde}=6$. Isto tako za ekvidistantne vrijednosti pogreške po brzini dolazi se do karakterističnih krivulja $u_F = \psi(e, de^*)$, $de=\text{const}$, (slika 3.6c) čiji su nagibi u odnosu na horizontalu za relativno male vrijednosti pogreške položaja također približno jednaki statičkom pojačanju pogreške položaja $K_{Fe}=10$. Za ekvidistantne vrijednosti pogreške gustoća prikazanih karakterističnih krivulja kvalitativno govori o statičkom pojačanju pogreške kao parametra koji se drži konstantnom vrijednosti. U tom smislu uspoređujući prikazane karakteristične krivulje na (slici 3.6b-c), dolazi se do zaključka da karakteristične krivulje $u_F = \psi(e^*, de)$, (slika 3.6b) zbog svoje manje gustoće prikaza, u odnosu na karakteristične krivulje $u_F = \psi(e, de^*)$, (slika 3.6c) imaju veću vrijednost statičkog pojačanja odnosno da vrijedi njihov međusobni odnos $K_{Fe} > K_{Fde}$. Isto tako iz prikazanih karakterističnih krivulja pri $e=\text{const}$ i $de=\text{const}$, zaključuje se da pri većim vrijednostima pogreške (na rubovima karakterističnih krivulja) postoji s obzirom na zahtjevani nulti stupanj neizrazitog djelovanja ($\eta=0$), nelinearnost odnosno lošija ugođenost neizrazitog analitičkog regulatora. Dobra podešenost **NAR**-a je osigurana za relativno male iznose pogreške položaja i brzine što je važno kod slijedne regulacije. Na (slici 3.6d) su za različite vrijednosti pogreške položaja i brzine prikazane u faznoj ravnini stanja nivo upravljačke krivulje. Skup nivo upravljačkih krivulja formira karakterističnu upravljačku površinu (slika 3.6a), dok skup karakterističnih krivulja formira karakterističnu ravninu (slika 3.6b-c). Na rubovima prikazane fazne ravnine vidi se izražena nelinearnost u smislu smanjenja statičkih vrijednosti pojačanja pogreške položaja i brzine. Za različite moguće vrijednosti parova pogreške (e, de) nivo upravljačke krivulje povezuju točke fazne ravnine koje imaju konstantan iznos upravljačkog napona u_F , dok je prirast upravljačke varijable između prikazanih nivo upravljačkih krivulja unaprijed usvojen i konstantnog je iznosa. Stoga gustoća nivo upravljačkih krivulja $\Psi(e, de, F^*, \beta^*) = \text{const}$, za određene vrijednosti F i β parametra (3.5) govori o odnosu statičkih pojačanja na pojedinim mjestima fazne ravnine (slika 3.6d). Prilikom ugađanja **PNAR**-a za druge vrijednosti parametara položaja K_{np} i brzine K_{nv} , dolazi se do faznih ravnina s drugačijim rasporedom nivo upravljačkih krivulja (slika 3.7). Smanjenjem vrijednosti parametra brzine na iznos $K_{nv}=2$, dolazi se do blažeg nagiba nivo upravljačkih krivulja u odnosu na os pogreške po položaju, što znači da za određenu konstantnu vrijednost pogreške brzine $de=de^*$ potreban je

znatan prirast pogreške po položaju Δe da bi nastupio prirast upravljačke varijable u u smislu da bi dovelo do preseljenja točke s jedne na drugu nivo upravljačku krivulju (slika 3.7a). U graničnom slučaju pri vrijednosti parametra $K_{nv}=0$ nivo upravljačke krivulje bile bi približno horizontalne što znači da se u tom slučaju radi o proporcionalnom **P-PNAR-u**.



Slika 3.7 Prikaz nelinearnih nivo upravljačkih krivulja $\Psi(e, de, F^*, \beta^*) = \text{const}$ pri $(u_F)_n = 2,277 \text{ V}$
a) $K_{np}=10, K_{nv}=2$; b) $K_{np}=5, K_{nv}=12$.

Nasuprot tome pri povećanju parametra brzine $K_{nv}=12$ tako da isti bude veći od parametra pozicije $K_{np}=5$, povećava se strmina nivo upravljačkih krivulja (slika 3.7b) u odnosu na os pogreške položaja. U ovom slučaju za inkrementalni porast upravljačke varijable dviju susjednih nivo upravljačkih krivulja potreban je mnogo manji prirast pogreške položaja Δe za konstantni iznos pogreške po brzini $de=de^*$. S daljim povećanjem parametra brzine K_{nv} u odnosu na parametar položaja dolazi do povećanja strmine nivo upravljačkih krivulja tako da one u graničnom slučaju pri $K_{np}=0$ postaju vertikalne krivulje. U tom slučaju kažemo da se radi o čistom derivacijskom djelovanju odnosno o **D-PNAR-u**. Nivo upravljačka krivulja nulte vrijednosti zove se još i prijeklopnica s jednom od osnovnih karakteristika da sadrži točku s nultim vrijednostima svih ulaznih varijabli $(e, de)=(0,0)$. Pri međusobno različitim vrijednostima parametara položaja i brzine, nelinearnost nivo upravljačkih krivulja (slika 3.7), na rubovima fazne ravnine osnovno je obilježje neizrazitog djelovanja **PNAR-a**. Stoga stanje minimalne pobuđenosti **PNAR-a**, kao rezultata njegovog početnog podešavanja biti će zadovoljeno jedino na središnjem dijelu fazne ravnine vezane za relativno male pogreške položaja $e \in \{-0,5 \dots 0,5\}$ i brzine $de \in \{-0,5 \dots 0,5\}$. Postupak početnog podešavanja **PI-PNAR-a**, potpuno bi tekao identično izloženom ugađanju **PD-PNAR-a**. Osnovna razlika je da u tom slučaju za postavnu veličinu umjesto upravljačke varijable u_F uzimamo njezinu derivaciju du_F/dt , što je osobito značajno prilikom prikaza i analize nivo upravljačkih krivulja u faznoj ravnini. Dakle potpuno

analogna razmatranja u faznoj ravlini kao i kod **PD-PNAR**-a vrijede i ovdje, stoga se njezina svojstva dalje detaljnije ne razmatraju.

3.1 Rezultati simulacije vođenja mobilnog robota sa početno podešenim **PD-PNAR**-om

Diferencijalnim jednadžbama (2.49), opisan je dinamički sustav mobilnog robota čiji je model u prostoru stanja dan tripletom matrica [38, 40], (prilog 4):

$$\mathbf{A} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & -KQ_{ii} & KQ_{ij} \\ 0 & 0 & KQ_{ij} & -KQ_{ii} \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ KR_{ii} & -KR_{ij} \\ -KR_{ij} & KR_{ii} \end{bmatrix}, \quad \mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}, \quad (3.6)$$

čije su komponente određene izrazima:

$$KR_{ii} = \frac{(J_m N^2 + h_{ii})}{(J_m N^2 + h_{ii})^2 - h_{ij}^2}, \quad KR_{ij} = \frac{h_{ij}}{(J_m N^2 + h_{ii})} KR_{ii}, \quad (3.7)$$


$$KQ_{ii} = D_m N^2 KR_{ii}, \quad KQ_{ij} = \frac{h_{ij}}{(J_m N^2 + h_{ii})} KQ_{ii}. \quad (3.8)$$

Ovdje h_{ii} i h_{ij} redom predstavljaju vlastite i unakrsne dinamičke momente tromosti mehanizma mobilnog robota svedene na izlaznu os vratila reduktora, koje se izračunavaju detaljno izvedenim izrazima u referenci [40]. Parametri istosmjernih električnih motora za dva rotacijska stupnja slobode gibanja mobilnog robota dani su tablicom 3.1.

Aktuator br.	1	2
Moment inercije rotora, kg m ²	0,0013	0,0013
Momentna konstanta, Nm/A	0,32	0,32
Naponska konstanta, Vs/rad	0,32	0,32
Koeficijent viskoznosti, Nms	0,0043	0,0043
Nazivni napon, V	90	90
Nazivna brzina, s ⁻¹	28	28
Odnos redukcije	10	10
Masa, kg	3,5	3,5

Tablica 3.1. Parametri istosmjernih električnih motora za mobilni robot sa dva rotacijska stupnja slobode gibanja.

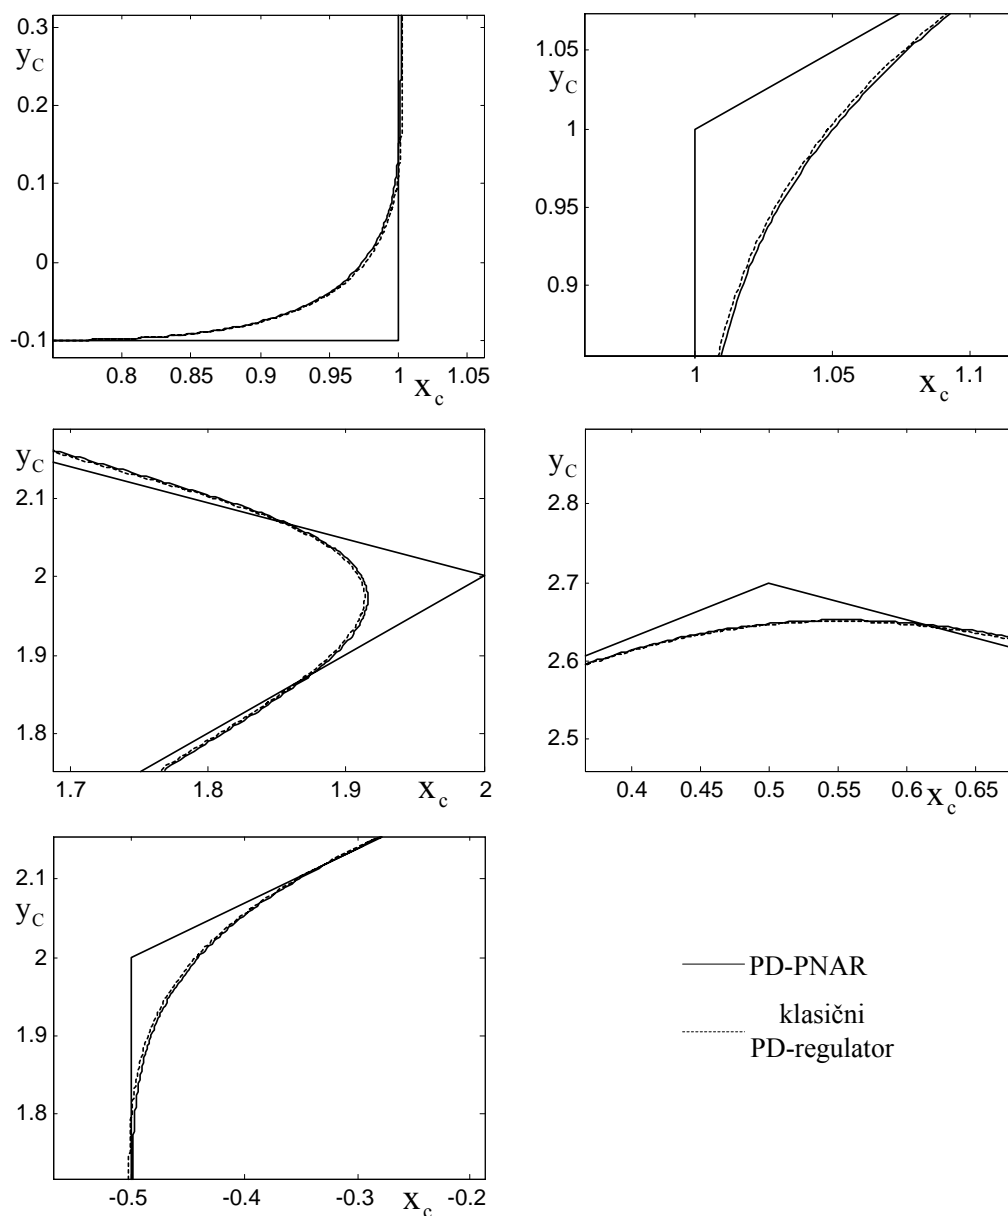
U ovoj disertaciji vođenje mobilnog robota vrši se u prostoru unutarnjih upravljanih koordinata, generiranom nominalnom trajektorijom iz prostora vanjskih koordinata [40], gdje se uz neprekidnost nominalne trajektorije postavlja zahtjev i za neprekidnost brzine i ubrzanja. Zbog osiguranja ravnomjernog gibanja bez trzaja prilikom prelaska s jednog segmenta trajektorije na drugi (prijelomne točke trajektorije) primijenjen je kvadratni zakon promjene ubrzanja [40,74]. Za odabranu referentnu trajektoriju zadanu točkama T_1, T_2, \dots, T_6 u prostoru vanjskih koordinata (slika 3.8), u nastavku izlaganja daju se rezultati simulacije vođenja mobilnog robota s implementiranim početno ugođenim **PD-PNAR**-om u usporedbi sa implementiranim klasičnim linearnim **PD** zakonom upravljanja.




Slika 3.8 Rezultati simulacije praćenja referentne trajektorije mobilnog robota pri nominalnoj brzini 0,4 (m/s) vođenog početno podešenim **PD-PNAR**-om i klasičnim linearnim **PD** zakonom upravljanja.

Detalji kretanja mobilnog robota referentnom trajektorijom nominalnom brzinom 0,4 m/s u okolini prijelomnih točaka s implementiranim početno podešenim **PD-PNAR**-om i klasičnim linearnim **PD** zakonom upravljanja prikazani su na slici 3.8a.


Usporedbom praćenja nominalne trajektorije sa slike 3.8 i 3.8a, vidljivo je da se početno ugođen **PD-PNAR** u svom radu, gotovo u potpunosti približio klasičnom linearnom **PD** regulatoru. O stanju minimalne pobuđenosti **PD-PNAR**-a govore pogreške položaja i brzine generaliziranih varijabli prikazane dijagramima na slici 3.9-12. Isprekidanim linijama prikazani su rezultati s implementiranim klasičnim linearnim **PD**-zakonom upravljanja, dok su punom linijom prikazani rezultati s implementiranim **PD-PNAR**-om.




Slika 3.8a Prikazi uvećanih detalja rezultata simulacije praćenja referentne trajektorije mobilnog robota prikazane slikom 3.8 u prostoru vanjskih koordinata.



Slika 3.9 Dijagram pogreške položaja lijevog pogonskog kotača, prilikom praćenja referentne trajektorije (slika 3.8) sa početno podešenim **PD-PNAR**-om parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$ i $P=2,27$.




Slika 3.10 Dijagram pogreške položaja desnog pogonskog kotača, prilikom praćenja referentne trajektorije (slika 3.8) sa početno podešenim **PD-PNAR**-om parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$.




Slika 3.11 Dijagram pogreške brzine lijevog pogonskog kotača, prilikom praćenja referentne trajektorije sa (slika 3.8), sa početno podešenim **PD-PNAR**-om parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$.


U jedan i drugi zakon upravljanja uključeno je predupravljanje s pojačanjem $P=2,27$. Pozitivna (negativna) pogreška položaja upravljane varijable govori o njezinom prebačaju (kašnjenju) u odnosu na zahtjevanu nominalnu vrijednost. Općenit zadatak upravljanja je smanjenje prebačaja odnosno kašnjenja upravljane varijable. Kod **PNAR**-a dolazi do promjene položaja centara izlaznih neizrazitih skupova pozicije i brzine. Pozitivnom prirastu pogreške položaja (slika 3.9-10) i brzine (slika 3.11-12) odgovara negativan prirast položaja centara izlaznih neizrazitih skupova položaja (slika 3.13) i brzine (slika 3.14). Općenito pozitivni prirast centra izlaznog neizrazitog skupa ulazne pogreške doprinosi povećanju izlazne neizrazite upravljačke varijable u_F , s tendencijom smanjenja pogreške.




Slika 3.12 Dijagram pogreške brzine desnog pogonskog kotača, prilikom praćenja referentne trajektorije (slika 3.8) sa početno podešenim **PD-PNAR**-om parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$.



Slika 3.13 Položaj centra izlaznog neizrazitog skupa pozicije Y_e početno podešenog **PD-PNAR**-a parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$, pri slijeđenju referentne trajektorije (slika 3.8).




Slika 3.14 Položaj centra izlaznog neizrazitog skupa brzine Y_{de} početno podešenog **PD-PNAR**-a parametara ($K_{Fe}=12$, $F_e=0,6$; $\beta_e=0,032$; $K_{Fde}=5$ $F_{de}=0,238$; $\beta_{de}=0,034$) i $U_m=15$; $P=2,27$, pri slijeđenju referentne trajektorije (slika 3.8).




Slika 3.15 Dijagramski prikaz upravljačkih varijabli (u_r) istosmjernog servosustava lijevog i desnog pogonskog kotača pri slijeđenju referentne trajektorije (slika 3.8) s implementiranim početno podešenim **PD-PNAR**-om parametara ($K_{Fe}=12$; $K_{Fde}=5$).

Pri vođenju mobilnog robota u prostoru unutarnjih upravljanih koordinata s implementiranim **PD-PNAR**-om, na dijagramima na slici 3.15 prikazane su promjene upravljačke varijable napona lijevog (u_r)_l i desnog servomotora (u_r)_d. Zbog dobre početne podešenosti **PD-PNAR**-a promjena upravljačke varijable implementiranog klasičnog linearnog PD zakona upravljanja se gotovo i ne razlikuju od prikazanih. Da bi pokazali da ta razlika ipak postoji, odnosno da bi i u fazi početnog podešavanja prikazali neizrazito djelovanje **PNAR**-a, na slici 3.16 prikazana je promjena neizrazite upravljačke varijable (Δu_r) u odnosu na linearni **PD**-zakon upravljanja. Iako je ta promjena kod ugođenog **PNAR**-a minimalnog iznosa ona ipak postoji i dolazi do izražaja kod zahtjevnijih parametara gibanja referentnom putanjom (npr. većih vrijednosti brzina). To dolazi do izražaja na slici 3.15-16, prilikom oštrijeg skretanja na kraju trećeg segmenta dane referentne putanje (slika 3.8).




Slika 3.16 Prirast neizrazite upravljačke varijabli (Δu_r) lijevog i desnog pogonskog kotača pri slijeđenju referentne trajektorije (slika 3.8) s implementiranim početno podešenim **PD-PNAR**-om ($K_{Fe}=12$; $K_{Fde}=5$) u odnosu na linearni **PD**-zakon upravljanja.

U uvjetima zatvorene povratne veze po položaju i brzini, zbog minimalnog neizrazitog djelovanja ugođenog **PNAR**-a statička pojačanja po položaju K_{Fe} i brzini K_{Fde} se minimalno razlikuju od pojačanja linearnog **PD**-regulatora ($K_{np}=12$, $K_{nv}=5$). Neizrazito djelovanje upravljačke varijable (Δu_r), (slika 3.16) direktna je posljedica neizrazitog prirasta položaja centra izlaznog neizrazitog skupa pogreške položaja ΔY_e i brzine ΔY_{de} uslijed nelinearne promjene statičkog pojačanja položaja ΔK_{Fe} i brzine ΔK_{Fde} . Vrijednosti nelinearnih pojačanja položaja K_{Fe} i brzine K_{Fde} pri vođenju mobilnog robota nominalnom brzinom (0,4 m/s) referentnom trajektorijom (slika 3.8) prikazani su dijagramom (slika 3.17).



Slika 3.17 Promjena vrijednosti nelinearnog statičkog pojačanja $K_{Fe} \approx 12$ i $K_{Fde} \approx 5$ početno podešenog **PD-PNAR**-a ($K_{Fe}=12$; $K_{Fde}=5$) istosmjernih servosustava lijevog i desnog pogonskog kotača pri slijeđenju referentne trajektorije (slika 3.8).

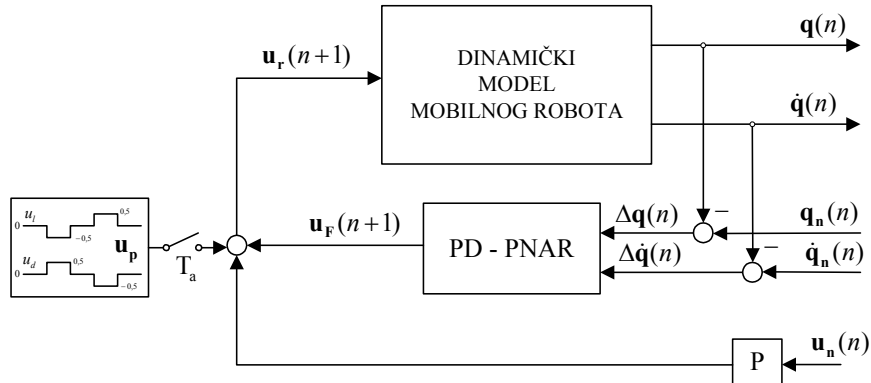
U uvjetima zatvorene petlje polovi sustava s implementiranim linearnim PD-zakonom upravljanja ($K_{np}=12$, $K_{nv}=5$) su redom $\lambda_1=-43.4285$, $\lambda_2=-38.8449$, $\lambda_3=-2.2672$ i $\lambda_4=-2.2813$. Polovi klasičnog **PD**-regulatora istosmjernih servosustava lijevog i desnog pogonskog kotača se međusobno malo razlikuju. To je zbog toga što pri gibanju mobilnog robota relativno malim brzinama ($v_c \approx 0,4$ m/s) sprezanje između pojedinih stupnjeva slobode gibanja je slabo. Manje vrijednosti odgovaraju polovima položaja dok veće vrijednosti odgovaraju polovima brzine. Prirast nelinearnog pojačanja ΔK_F , osim prirasta neizrazite upravljačke varijable za Δu_r (slika 3.16) za direktnu posljedicu ima i promjenu položaja polova u lijevoj Gausovoj kompleksnoj poluravnini (slika 3.18).



Slika 3.18 Dijagramski prikaz promjene vrijednosti sistemskih polova λ_i ($i=1,..4$) uslijed neizrazitog djelovanja početno podešenog PD-PNAR-a ($K_{Fe} \approx 12$; $K_{Fde} \approx 5$) pri slijeđenju referentne trajektorije (slika 3.8).


U postupku početnog podešavanja, određivani su F i β parametri nelinearnog **PD-PNAR**-a kako bi isti u graničnom slučaju (minimalne pobuđenosti upravljačke površine) u uvjetima zatvorene petlje po položaju i brzini uspješno obavljao emulaciju linearnog **PD**-regulatora. Osim upravljanja u uvjetima zatvorene regulacijske petlje ovdje postoji upravljanje i u otvorenoj regulacijskoj petlji tzv. unaprijedno vođenje ili predupravljanje (eng. *feedforward*), s osnovnom svrhom eliminiranja statičke pogreške dinamičkog sustava (slika 3.19). Jedan od glavnih nedostataka ovakvog načina upravljanja je nemogućnost otklanjanja dodatnih nemjerljivih poremećaja konstantnih iznosa koji se mogu javiti pri gibanju mobilnog robota referentnom putanjom. U tu svrhu koristi se generator poremećajnog signala (\mathbf{u}_p) koji dodatno djeluje na upravljačku varijablu (\mathbf{u}_r). Poremećajni signal ima pravokutni oblik amplitude 0,5 V koji se mijenja periodično svakih 5s. Dakle u vremenskim periodima od 5s poremećajni signal jednakih protufaznih amplituda od 0,5 V djeluje simultano na lijevi i desni servomotor (slika 3.19).

Amplitudi od 0,5 V zapravo odgovara maksimalno očekivana amplituda poremećajne veličine izlazne generalizirane varijable brzine dinamičkog sustava transformirane na stranu upravljačke varijable.




Slika 3.19 Prikaz vođenja mobilnog robota **PNAR**-om u uvjetima zatvorene regulacijske petlje po položaju i brzini sa predupravljanjem pojačanja P u uvjetima otvorene regulacijske petlje.

Ako se konstantnom u principu nemjerljivom poremećaju dodaju i poremećaji uslijed početnih uvjeta lijeve i desne generalizirane varijable u iznosu $\Delta q_l = -0,17$ i $\Delta q_d = 0,17$ dolazi se do dijagrama pogreške položaja Δq i brzine $\Delta \dot{q}$ izlaznih upravljanih koordinata. Uslijed osigurane asimptotske stabilnosti sustava poremećaji tipa početnih uvjeta iščezavaju tokom vremena, dok se pogreška položaja uslijed nemjerljivog poremećaja konstantnog iznosa zadržava unutar sustava (slika 3.20).




Slika 3.20 Dijagram pogreške položaja pogonskih kotača, prilikom vođenja mobilnog robota referentnom trajektorijom (slika 3.8), uz generiranje nemjerljivog poremećaja konstantnog iznosa (slika 3.19), te početnog poremećaja $\Delta q_l = -0,17$ i $\Delta q_d = 0,17$




Slika 3.21 Dijagram pogreške brzine pogonskih kotača, prilikom vođenja mobilnog robota referentnom trajektorijom (slika 3.8), uz generiranje nemjerljivog poremećaja konstantnog iznosa (slika 3.19), te početnog poremećaja $q_1 = -0,17$ i $\Delta q_d = 0,17$.

To je zbog toga što dinamički sustav s projektiranim slijednim **PD-PNAR**-om posjeduje astatizam prvog reda. Na slici 3.21 pri normaliziranim vremenski diskretnim koracima (n) prikazana je i pogreška brzine izlaznih upravljanih varijabli. Kvaliteta vođenja pri nemjerljivom poremećajnom djelovanju konstantnog iznosa i predupravljanjem u otvorenoj regulacijskoj petlji ne zadovoljava. Uvođenjem integralnog djelovanja na izlazu slijednog **PD-PNAR**-a prema slici 2.17, $M=1$ omogućeno je eliminiranje tokom vremena bilo kojeg slučajnog nemjerljivog poremećaja konstantnog iznosa i u tom slučaju nije potrebno predupravljanje u otvorenoj regulacijskoj petlji.




Slika 3.22 Dijagram izlazne pogreške položaja pogonskih kotača, prilikom vođenja mobilnog robota referentnom trajektorijom (slika 3.8), uz implementirani **PD-PNAR** sa dodatnim integracijskim djelovanjem na izlazu pojačanja $K_I=5$, ($M=1$, slika 2.17)



Slika 3.23 Dijagram izlazne pogreške brzine pogonskih kotača, prilikom vođenja mobilnog robota referentnom trajektorijom (slika 3.8), uz implementirani **PD-PNAR** sa dodatnim integracijskim djelovanjem na izlazu pojačanja $K_I=5$, ($M=1$, slika 2.17)


Dijagramski prikaz promjene izlazne pogreške položaja i brzine upravljanih koordinata po normaliziranim vremenski diskretnim koracima (n) prikazan je na slikama 3.22-23, gdje je vremensko iščezavanje pogreške uslijed poremećaja tipa početnog uvjeta i konstantnih nemjerljivih poremećaja sasvim evidentno. Potrebno neizrazito upravljačko djelovanje $u_F(n)$ po normaliziranim vremenski diskretnim koracima (n) uslijed konstantnih nemjerljivih poremećaja (slika 3.19) i poremećaja tipa početnog uvjeta sa predupravljanjem u otvorenoj regulacijskoj petlji (slika 3.19; slika 2.17 $M=0$) prikazano je na slici 3.24.



Slika 3.24 Dijagram neizrazite upravljačke varijable $u_F(n)$ servosustava pogonskih kotača pri vođenju mobilnog robota referentnom trajektorijom (slika 3.8) uz implementirani **PD-PNAR** (slika 2.17 $M=0$), te djelovanje nemjerljivog poremećaja konstantnog iznosa (slika 3.19) i početnog poremećaja.

Odavde je moguće zaključiti da se poremećajno djelovanje konstantnog iznosa nastoji kompenzirati neizrazitim djelovanjem **PD-PNAR**-a, pri čemu u idealnom slučaju vrijedi da je

$\Delta u_F = -\text{sgn}(u_P)$, gdje $\text{sgn}(u_P)$, označava predznak poremećajne amplitude (u_P). U realnom slučaju zbog nedovoljnog neizrazitog kompenzacijskog djelovanja, odnosno nedovoljnog astatizma dinamičkog sustava pri negativnim vrijednostima dolazi do smanjenja, a pri pozitivnim vrijednostima poremećajne amplitude (u_P) do povećanja upravljane varijable Δq (slika 3.20), pri čemu vrijedi da je $\text{sgn}(\Delta u_F) = -\text{sgn}(\Delta q)$. Regulacijsko djelovanje neizrazite upravljačke varijable $u_F(n)$ naročito dolazi do izražaja kod implementiranog **PD-PNAR**-a (slika 3.25) sa integracijskim djelovanjem na izlazu (slika 2.17, $M=1$), pri čemu se eliminiraju trajna regulacijska odstupanja (statičke pogreške slika 3.22). U tom slučaju nije potrebno predupravljanje o čemu govore i posljednja dva dijagrama neizrazite upravljačke varijable $u_F(n)$.



Slika 3.25 Dijagram neizrazite upravljačke varijable $u_F(n)$ servosustava pogonskih kotača pri vođenju mobilnog robota referentnom trajektorijom (slika 3.8), uz implementirani **PD-PNAR** s integracijskim djelovanjem na izlazu pojačanja $K_I=5$, ($M=1$, slika 2.17)

4. POSTUPAK SAMOORGANIZIRANJA POBOLJŠANOG NEIZRAZITOG ANALITIČKOG REGULATORA

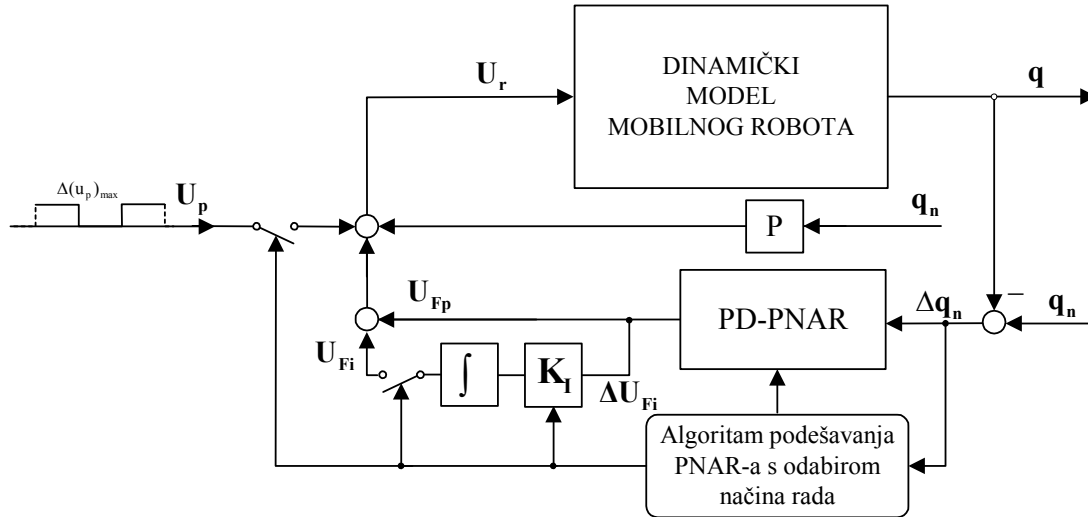
Neizrazita upravljačka varijabla u_F , nelinearna je funkcija svojih ulaznih varijabli i slobodnih parametara koji se u općem slučaju mogu mijenjati (2.55). Ako se parametri neizrazitog regulatora mijenjaju tokom vremena, dolazi se do pojma neizrazitog regulatora s vremenski varijabilnim parametrima. Parametri neizrazitog regulatora su promjenjivi po normaliziranim vremenski diskretnim koracima (n) i u općenitom slučaju se mogu mijenjati u **OFF** [51,52,53] ili u **ON-line** [54,55,56] modu rada. Stoga u općenitom slučaju neizrazitu upravljačku varijablu (2.55) u normaliziranom vremenski diskretnom koraku (n) zapisujemo u obliku

$$u_F(n) = \Psi(e, de, \varepsilon_{ij}^*, \alpha_j^*, F_j, \beta_j, T_j^*, k_j^*, n) , \quad i=1, \dots, n_j ; \quad j=1, \dots, m , \quad (4.1)$$

u kojem se fiksne vrijednosti odabranih parametara j -te ulazne varijable označene zvjezdicom mogu u daljem razmatranju izostaviti, dobivajući na taj način zapis prikladnijeg oblika

$$u_F(n) = \Psi(e, de, F_j, \beta_j, n) , \quad j=1, \dots, m . \quad (4.2)$$

Potreba za promjenom parametara neizrazitog regulatora javlja se uslijed različitih oblika poremećaja pri vođenju objekta regulacije. Tako na primjer moguće promjene parametara i uvjeta rada dinamičkog sustava te nedovoljno točna modeliranost dinamike objekta regulacije imaju za posljedicu potrebu organiziranja neizrazitog regulatora sa svrhom bolje kompenzacije poremećaja. Prvi samoorganizirajući neizraziti regulator bio je predložen od Mamdaniya i Procyka 1979. godine [73]. Od tada pa do danas u literaturi se neizrazitim regulatorima takvih sposobnosti pridjeljuju različiti atributi kao adaptivni, samoučeći, samopodešavajući te ekspertni regulatori sa promjenjivom bazom pravila regulacije i sposobnošću obučavanja baze neizrazitih pravila (eng. *Fuzzy rule base training*). Za razliku od klasičnih neizrazitih regulatora kod kojih se podešavanje početnih vrijednosti parametara vrši na bazi iskustva operatera, kod analitičkog neizrazitog regulatora se početne vrijednosti parametara podešavaju algoritmom i to neposredno prije uključenja u krug upravljanja u OFF-line modu. U tom smislu jedanput podešeni neizraziti regulator ima statičku vremenski invarijantnu upravljačku strukturu u ON-line modu rada. Ovdje dakle nije riječ o klasičnom neizrazitom regulatoru nego o samoorganizirajućem neizrazitom analitičkom regulatoru kod kojega atribut »samoorganizirajući« osim oblikovanja neizrazite upravljačke plohe podešavanjem slobodnih parametara u OFF-line modu rada, uključuje i promjenu strukture **PNAR**-a (slika 4.1).



Slika 4.1 *Općenita struktura samoorganiziranja **PNAR**-a po pogrešci slijeđenja nominalne upravljačke varijable.*

U podpoglavlju 4.1 predložen je nelinearni algoritam oblikovanja neizrazite upravljačke plohe (4.2) podešavanjem F i β slobodnog parametra **PD-PNAR**-a u skladu sa zadatkom regulacije odnosno dinamičkim karakteristikama vođenog objekta regulacije. Do promjene strukture se dolazi kada se ulazne varijable **PNAR**-a nalaze u području oko nule, odnosno kad izlazna pogreška upravljane varijable padne ispod unaprijed određene vrijednosti. Nova struktura sadrži integralno djelovanje (slika 4.1) čiji je zadatak svođenje preostale pogreške **PD-PNAR**-a, i procijenjene emulirane pogreške stacionarnog stanja na nulu. Pritom ovisno o predloženoj strukturi samoorganiziranja **PNAR**-a (podpoglavlje 5.6), dana je mogućnost podešavanja integralnog pojačanja predloženim algoritmima u podpoglavlju 5.5, čime se u postupku samoorganiziranja dodatno doprinosi oblikovanju neizrazite upravljačke plohe (4.2).

4.1 Proces adaptacije slobodnih parametara **PNAR**-a

Izostanak dinamike **PNAR**-a u ON-line modu rada nadomješta se dinamikom ulaznih varijabli odnosno pogreškama po položaju (e) i brzini (de), što ga po karakteristikama kao što je bilo pokazano u prethodnom poglavlju približava regulatoru u prostoru stanja. Upravljačka varijabla $u_F(n+1)$ u slijedećem normaliziranom vremenski diskretnom koraku ($n+1$) uslijed prirasta F i β parametra iznosa ΔF i $\Delta\beta$ ima vrijednost

$$u_F(n+1) = \Psi(e, de, F_j + \Delta F_j, \beta_j + \Delta\beta_j, n+1), \quad j=1, \dots, m. \quad (4.3)$$

Za prirast upravljačke varijable na temelju prethodna dva izraza dobivamo

$$\Delta u_F(n) = u_F(n+1) - u_F(n) = \Psi(e, de, F_j + \Delta F_j, \beta_j + \Delta \beta_j, n+1) - \Psi(e, de, F_j, \beta_j, n) . \quad (4.4)$$

Ovdje valja napomenuti da se pogreške pozicije i brzine smatraju sporo promjenjivim vremenskim funkcijama te da je između dva susjedna normalizirana vremenski diskretna koraka njihov utjecaj na formiranje upravljačke varijable zanemariv. Stoga razvojem u Tejlorov red upravljačke neizrazite varijable (4.3) kao nelinearne funkcije prirasta F i β parametara iznosa ΔF i $\Delta \beta$ u odnosu na prethodni korak dobiva se u obliku diskretnog reda:

$$u_F(n+1) = u_F(n) + (\Delta F_j \frac{\partial}{\partial F_j} + \Delta \beta_j \frac{\partial}{\partial \beta_j}) u_F(n) + \frac{1}{2!} (\Delta F_j \frac{\partial}{\partial F_j} + \Delta \beta_j \frac{\partial}{\partial \beta_j})^2 u_F(n) + \dots , \quad (4.5)$$

ili u općenitom obliku:

$$u_F(n+1) = \sum_{j=1}^m \sum_{i=0}^{\infty} \frac{1}{i!} (\Delta F_j \frac{\partial}{\partial F_j} + \Delta \beta_j \frac{\partial}{\partial \beta_j})^i u_F(n), \quad j=1, \dots, m . \quad (4.6)$$

Uz dovoljno male priraste parametara uzimaju se prva dva pribrojnika Tejlorovog reda, odnosno zanemaruju se pribrojnici višeg reda (sa većom derivacijom od prve), stoga vrijedi

$$u_F(n+1) = \Psi(e, de, F_j, \beta_j, n) + \Delta F_j \frac{\partial \Psi(e, de, F_j, \beta_j, n)}{\partial F_j} + \Delta \beta_j \frac{\partial \Psi(e, de, F_j, \beta_j, n)}{\partial \beta_j} . \quad (4.7)$$

Kako parcijalne derivacije neizrazite upravljačke varijable po F_j i β_j parametru j -te ulazne varijable $j=1, \dots, m$, redom predstavljaju funkcije osjetljivosti Θ_{F_j} (2.73) i Θ_{β_j} (2.77), upravljačke varijable u_F , onda se u postupku adaptacije uz prethodni izraz prirast neizrazite upravljačke varijable (4.4) zapisuje u jednostavnijem inkrementalnom obliku:

$$\Delta u_F(n) = \Delta \Psi(e, de, F, \beta, n) = (\Theta_{F_e} \Delta F_e + \Theta_{\beta_e} \Delta \beta_e + \Theta_{F_{de}} \Delta F_{de} + \Theta_{\beta_{de}} \Delta \beta_{de})_{(n)} , \quad (4.8)$$

na osnovu kojeg dolazimo do rekurzivne jednadžbe za izračunavanje upravljačke varijable u slijedećem normaliziranom vremenski diskretnom koraku

$$u_F(n+1) = u_F(n) + (\Theta_{F_e} \Delta F_e + \Theta_{\beta_e} \Delta \beta_e + \Theta_{F_{de}} \Delta F_{de} + \Theta_{\beta_{de}} \Delta \beta_{de})_{(n)} . \quad (4.9)$$

Promjenu parametara vršimo algoritmom adaptacije s ciljem osiguranja minimalne vrijednosti definirane funkcije cilja E_y , koja s obzirom na izlaznu pogrešku sustava glasi:

$$E_y = \frac{1}{2} (y - y_n)^2 . \quad (4.10)$$

Dakle osnovni je zadatak obučavanjem **PNAR**-a, odrediti F i β parametre s ciljem minimiziranja pogreške po položaju i brzini (slika 4.1). Ako generalno slobodni parametar označimo s \mathcal{G} , pogrešku pri toj vrijednosti parametra sa $e(\mathcal{G})$ onda se algoritmom adaptacije kod nove vrijednosti parametra mora osigurati da vrijedi

$$e(\mathcal{G} + \Delta \mathcal{G}) < e(\mathcal{G}) . \quad (4.11)$$

Razvojem u Tejlorov red u okolini pogreške $e(\mathcal{G})$ pri parametru \mathcal{G} dobiva se

$$e(\mathcal{G} + \Delta\mathcal{G}) = \sum_{i=1}^{\infty} \frac{(\Delta\mathcal{G})}{i!} \frac{\partial^i e(\mathcal{G})}{\partial \mathcal{G}} . \quad (4.12)$$

Uzimanjem prva dva pribrojnika Tejlorovog reda, odnosno odbacivanjem pribrojnika višeg reda sa dovoljnom točnošću može se pisati

$$e(\mathcal{G} + \Delta\mathcal{G}) = e(\mathcal{G}) + \nabla e(\mathcal{G}) \Delta\mathcal{G} , \quad (4.13)$$

gdje simbol » ∇ « predstavlja nabla operator odnosno parcijalnu derivaciju (gradijent) pogreške po parametru. U skladu sa izrazom (4.11) mora vrijediti $\text{sgn}\{\nabla e(\mathcal{G})\} = -\text{sgn}\{\Delta\mathcal{G}\}$. Kako se promjena pogreške Δe tokom vremena mora smanjivati s promjenom parametra $\Delta\mathcal{G}$ potrebno je pronaći onu promjenu parametara koja dovodi do najbržeg smanjenja pogreške. Iz uvjeta

$$\frac{\partial \Delta e(\mathcal{G})}{\partial \Delta\mathcal{G}} = \nabla e(\mathcal{G}) + \frac{\partial \nabla e(\mathcal{G})}{\partial \Delta\mathcal{G}} \Delta\mathcal{G} = 0 , \quad (4.14)$$

neposredno slijedi

$$\Delta\mathcal{G} = -\eta_u \nabla e(\mathcal{G}) , \quad (4.15)$$

gdje η_u predstavlja koeficijent obučavanja koji označava i brzinu promjene parametara po gradijentu pogreške $\nabla e(\mathcal{G})$

$$\eta_u = \frac{\partial \Delta\mathcal{G}}{\partial \nabla e(\mathcal{G})} . \quad (4.16)$$

Koeficijent učenja može biti konstantnog iznosa, a može se mijenjati po nekoj funkcionalnoj zavisnosti koja osigurava smanjenje pogreške (4.11). Prilikom podešavanja F parametra koeficijent učenja η_F se mijenja tokom svake iteracije po zakonitosti

$$\eta_F = A_F e^{\frac{\sigma_F}{\text{ISE}_F} \frac{\text{ISE}_F - \text{ISE}}{\text{ISE}_F}} , \quad (4.17)$$

gdje su A_F i σ_F konstante pozitivnih vrijednosti, a **ISE** (eng. *Integral Square Error*) predstavlja integralni kriterij dan integralom kvadratne pogreške u diskretnom obliku koji se računa na kraju svake iteracije

$$\text{ISE} = \sum_{n=1}^N e^2 T_s , \quad (4.18)$$

dok je sa ISE_F definirana njegova početna vrijednost. U ovisnosti o vrijednosti koeficijenta učenja η_F , koeficijent učenja β parametra mijenja se u svakom normaliziranom vremenski diskretnom koraku (n), a poprima vrijednost

$$\eta_{\beta}(n) = -\beta^2(n) \frac{\partial \beta(n)}{\partial F(n)} A_{\beta} e^{\sigma_{\beta} \frac{ISE_{\beta} - ISE}{ISE_{\beta}}}, \quad (4.19)$$

gdje je A_{β} pozitivna konstanta koja predstavlja faktor obučavanja. Prethodni izraz je empirijski dobivena funkcija koja se temelji na iskustvu stečenim magistarskim radom [40], i dugotrajnim interakcijskim radom sa elektroničkim računalom. Koeficijenti učenja definirani izrazima (4.17) i (4.19) u skladu sa izrazom (4.11) osiguravaju proces podešavanja **PNAR**-a modificiranom gradijentnom metodom (4.15). Gradijent pogreške po parametru $\nabla e(\mathcal{G})$ dobiva se uzastopnim derivacijama

$$\nabla e(\mathcal{G}) = \frac{\partial E_y}{\partial y} \frac{\partial y}{\partial u_F} \frac{\partial u_F}{\partial \mathcal{G}}, \quad (4.20)$$

gdje je na osnovu (4.10) prvi član jednak izlaznoj pogrešci Δy , drugi član kod **SISO** sustava jednak prijenosnoj funkciji dinamičkog sustava, dok je trećim članom dana osjetljivost Θ_g upravljačke veličine o F (2.73) i β (2.77) parametru. Stoga prethodni izraz zapisujemo u jednostavnijem obliku

$$\nabla e(\mathcal{G}) = \Delta y G \Theta_g = \Delta y \Omega_g, \quad (4.21)$$

gdje $\Omega_g = G \Theta_g$ predstavlja osjetljivost izlazne varijable dinamičkog sustava o parametru \mathcal{G} . Kod multivarijabilnog sustava mobilnog robota, zbog relativno malih brzina gibanja, u dinamičkom smislu slabo je sprezanje između pojedinih stupnjeva slobode gibanja. Stoga se na osnovu pogreške po položaju i brzini jednog pogonskog kotača podešavaju F i β parametri neizrazitog regulatora servosustava tog pogonskog kotača. Ne gubeći na kvaliteti podešavanja, ovdje se uzima da se osjetljivosti upravljačke varijable slobodnih parametara direktno prenose s ulaza na izlaz dinamičkog sustava, stoga se definira algoritam podešavanja (4.15) u konačnom obliku

$$\Delta \mathcal{G}(n) = -(\eta_u \Delta y \Theta_g)_n + \alpha_g \Delta \mathcal{G}(n-1) \quad n=1,2,\dots,N. \quad (4.22)$$

Koeficijentom α_g definiran je zamah čijim se izborom utječe na brzinu adaptacije slobodnih parametara. Pomoću prethodno definiranog algoritma adaptacije, na osnovu ulazne j -te varijable pogreške pozicije ($j=1$) i brzine ($j=2$) i-tog stupnja slobode gibanja u slijedećem ($n+1$) normaliziranom vremenski diskretnom koraku F i β parametar dobiva se izrazima:

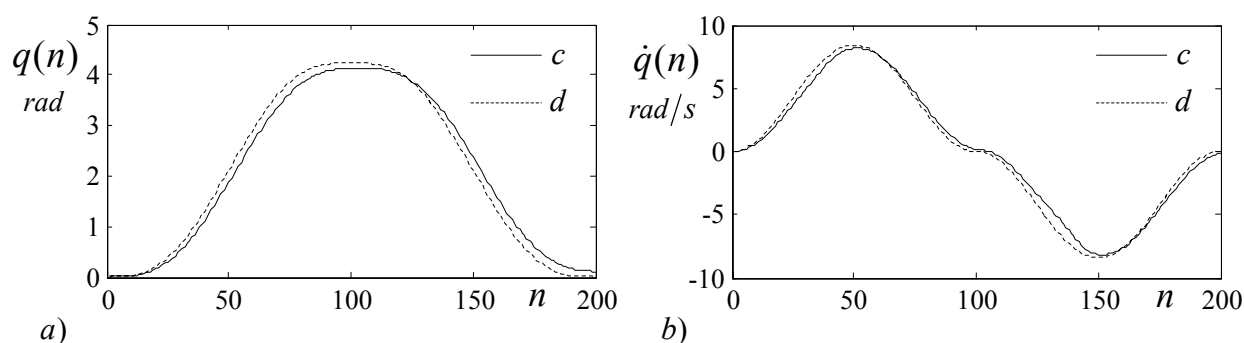
$$\begin{aligned} F_j^{(i)}(n+1) &= F_j^{(i)}(n) - \eta_{F_j}^{(i)} \Theta_{F_j}^{(i)} \Delta q_j^{(i)}(n) + \alpha_{F_j}^{(i)} \Delta F_j^{(i)}(n-1), \quad i,j=1,2, \\ \beta_j^{(i)}(n+1) &= \beta_j^{(i)}(n) - \eta_{\beta_j}^{(i)} \Theta_{\beta_j}^{(i)} \Delta q_j^{(i)}(n) + \alpha_{\beta_j}^{(i)} \Delta \beta_j^{(i)}(n-1). \end{aligned} \quad (4.23)$$

Izloženi postupak adaptacije modificiranom gradijentnom metodom testiran je pri jednostavnoj linearnoj putanji mobilnog robota, zakretanjem pogonskih kotača u prostoru unutarnjih upravljanih koordinata za kut $1,35\pi$.

parametri	e	de
σ_F	8	2
σ_β	8	2
A_F	0,16	0,14
A_β	0,67	0,97
ISE_F	0,09	0,81
ISE_β	0,09	0,81
α_F	0,5	0,1
α_β	0,5	0,1

Tablica 4.1 Osnovni parametri adaptacije početno ugođenog **PD-PNAR-a**.

Kao referenca u 200 normaliziranih vremenski diskretnih koraka, vremena uzorkovanja ($T_s=0,01s$), uzeto je gibanje mobilnog robota kosinusnim profilom brzine ($\varepsilon=100$), (slika 4.2b), linearnom putanjom u oba smjera (slika 4.2a). Postupak adaptacije započinje odabranim parametrima danim u tablici 3.1. Postignuta pozicija i brzina na kraju jedne reference, predstavlja ujedno početni uvjet pozicije i brzine za sljedeću referencu i tako redom proces se adaptiranja nastavlja dok integral kvadratne pogreške pozicije (ISE_e), u diskretnom obliku (4.18) ne padne ispod unaprijed zadane vrijednosti.



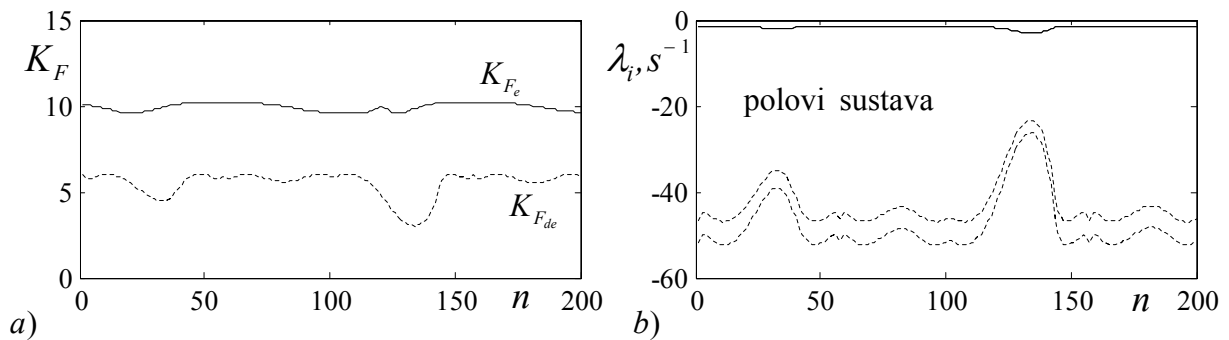
Slika 4.2 a) Nominalna (-d) i ostvarena pozicija (-c) početno ugođenog **PNAR-a** ($K_{np}=10$, $K_{nv}=6$), b) nominalna (-d) i ostvarena brzina (-c) podešenog **PNAR-a** u prostoru unutarnjih upravljanih koordinata.

Početnim podešavanjem **PNAR**-a (slika 4.1) pri $U_m=15V$, postupkom opisanim u prethodnom poglavlju dolazi se do parametara **PD-PNAR**-a servosustava lijevog i desnog pogonskog kotača sljedećih vrijednosti

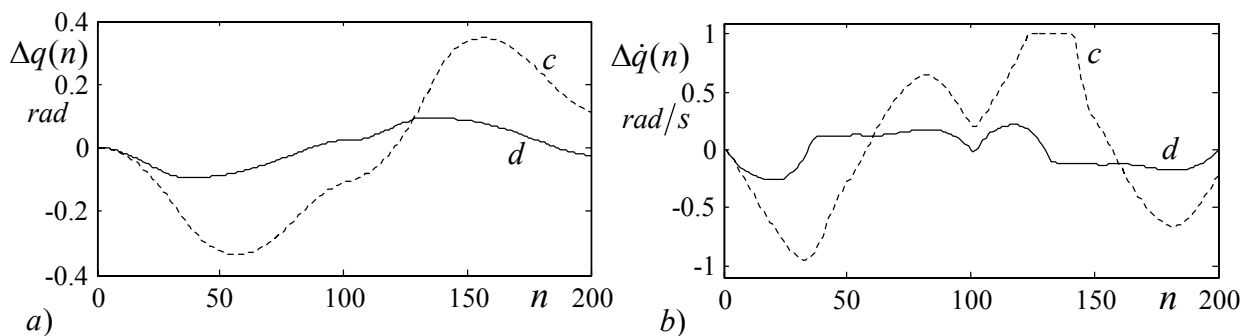
$$F_e=0,487 \quad \beta_e=0.0329 \quad F_{de}=0,282 \quad \beta_{de}=0.0341 \quad . \quad (4.24)$$

Neizrazite vrijednosti pojačanja pozicije (K_{Fe}) i brzine (K_{Fde}) **PD-PNAR**-a servosustava lijevog i desnog pogonskog kotača prikazane su dijagramom na slici 4.3a, dok su polovi sustava prikazani dijagramom na slici 4.3b. Relativno veći pad neizrazitog pojačanja po brzini utječe na smanjenje vrijednosti polova brzine, što iste približava a polove pozicije blago udaljava od ishodišta Gausove kompleksne ravnine (slika 4.3). Postupak adaptacije započinje parametrima dobivenim početnim ugađanjem neizrazitog regulatora (3.24) i parametrima adaptiranja danim tablicom 3.1, a završava kad integralni kriterij kvadratne pogreške pozicije (4.18) dostigne željenu vrijednost $ISE=0,0073$. Nakon 60 promjena referenci dostignute su sljedeće vrijednosti slobodnih parametara

$$F_e=49,5 \quad \beta_e=0,0003 \quad F_{de}=19,5 \quad \beta_{de}=0,0073 \quad . \quad (4.25)$$

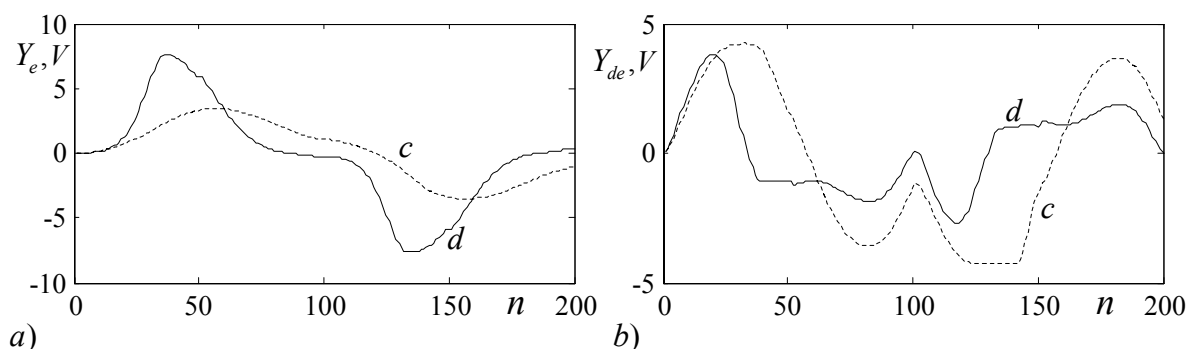


Slika 4.3 a) Neizrazite vrijednosti pojačanja pozicije (K_{Fe} , V/rad) i brzine (K_{Fde} , Vs/rad) početno podešenog **PNAR**-a ($K_{np}=10$, $K_{nv}=6$);
b) Polovi sustava u uvjetima zatvorenih regulacijskih petlji.



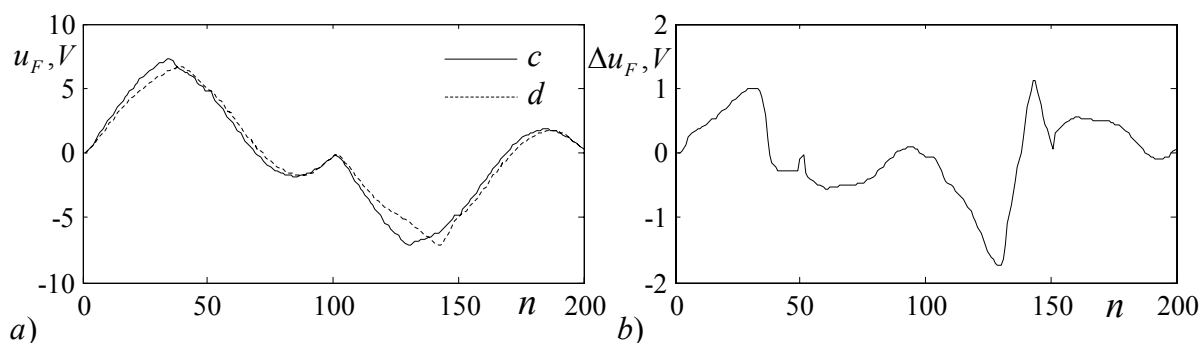
Slika 4.4 Pogreška pozicije a), brzine b) na početku (-c) i na kraju procesa adaptacije nakon 60 iteracija (promjena referenci) (-d).

Postupkom adaptiranja se maksimalna početna vrijednost pogreške po poziciji smanjila četiri, a pogreška brzine približno pet puta. Pogreška pozicije (Slika 4.4a) i brzine (slika 4.4b) početno ugođenog **PD-PNAR**-a, na početku podešavanja i nakon 60 iteracija (promjena referenci) po normaliziranim vremenski diskretnim koracima (n) prikazana je slijedećim dijagramima.



Slika 4.5 Položaj centra izlaznog neizrazitog skupa pogreške pozicije Y_e a), i pogreške brzine Y_{de} b) na početku (-c) i na kraju procesa adaptacije nakon 60 promjena referenci (-d).

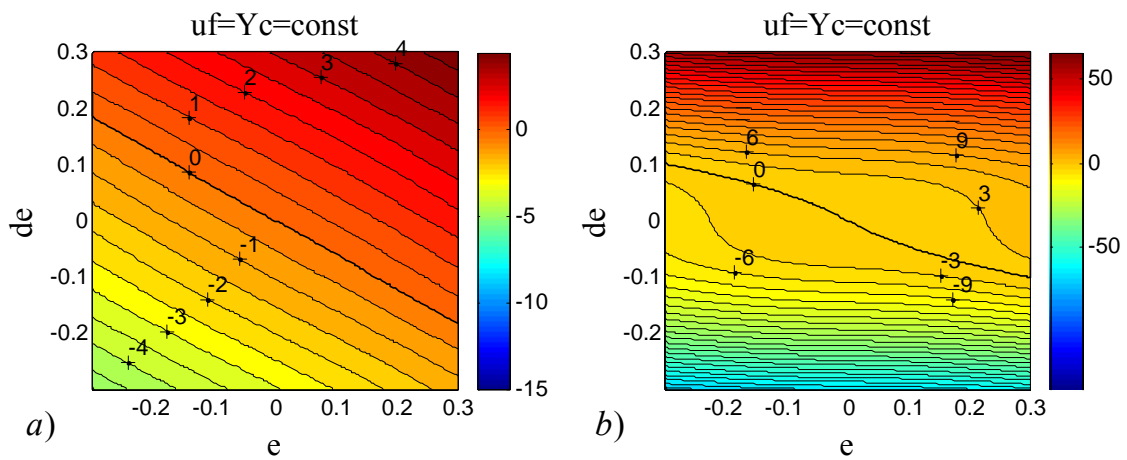
Izlazna pogreška položaja Δq i brzine $\Delta \dot{q}$ (Slika 3.4), kao ulazne varijable neizrazitog regulatora utječu na pomak centara izlaznih neizrazitih skupova pogreške pozicije Y_e (slika 4.5a) i brzine Y_{de} (slika 4.5b) koji sudjeluju pri formiranju neizrazite upravljačke varijable $u_F(n)$. U odnosu na početno ugađanje neizrazitog regulatora (c), nakon 60 iteracija (promjena referenci) položaji centara izlaznih neizrazitih skupova se izoštravaju (grupiraju) (d).



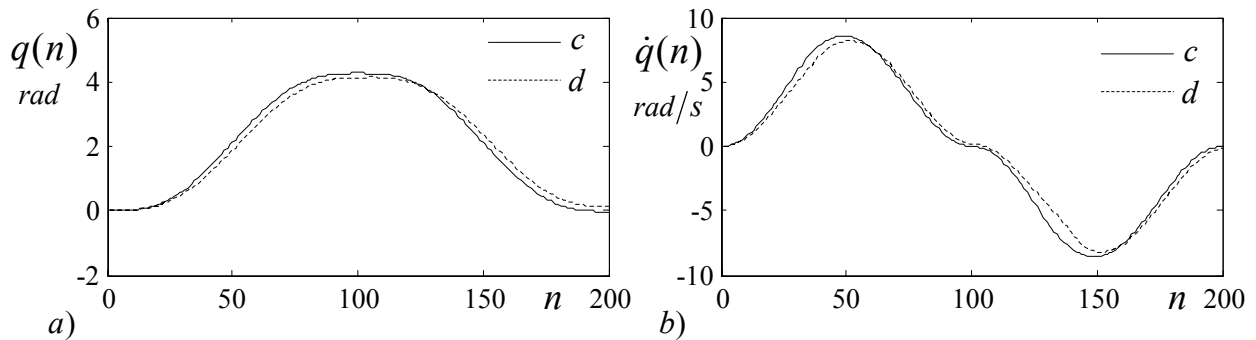
Slika 4.6 a) Vrijednosti neizrazite upravljačke varijable $u_F(n)$ na početku (-d) i na kraju procesa adaptiranja (60 promjena referenci) (-c) i prikaz promjene upravljačke varijable $\Delta u_F(n)$ nakon procesa adaptiranja u odnosu na početno ugođeni **PD**-neizraziti regulator b).

Promjena neizrazite upravljačke varijable po normaliziranim vremenski diskretnim koracima (n) na početku podešavanja **PD-PNAR**-a (d) i na kraju procesa adaptacije (c) je prikazana

dijagramima na (slici 4.6a). Zasebnim dijagramom zbog bolje uočljivosti na (slici 4.6b) zorno je prikazana promjena neizrazite upravljačke varijable $\Delta u_F(n)$ u odnosu na početno podešeni **PD-PNAR**. Početnim podešavanjem **PD-PNAR**-a, formira se karakteristična površina upravljanja čija je ploha približno ravna, a prijeklopnica je najbliža nivo upravljačkoj krivulji prvog reda. Ograničavajući se na male pogreške slijedne regulacije neizrazita upravljačka veličina $u_F = \text{const}$ prikazana je u dijelu fazne ravnine stanja za različite vrijednosti ulaznih varijabli (pogreške pozicije i brzine) iz podskupa $e, de \in \{-0,3, \dots, 0,3\}$ na početku (slika 4.7a) i na kraju procesa adaptacije (slika 4.7b). U ovom slučaju prijeklopnica je krivulja višeg reda.



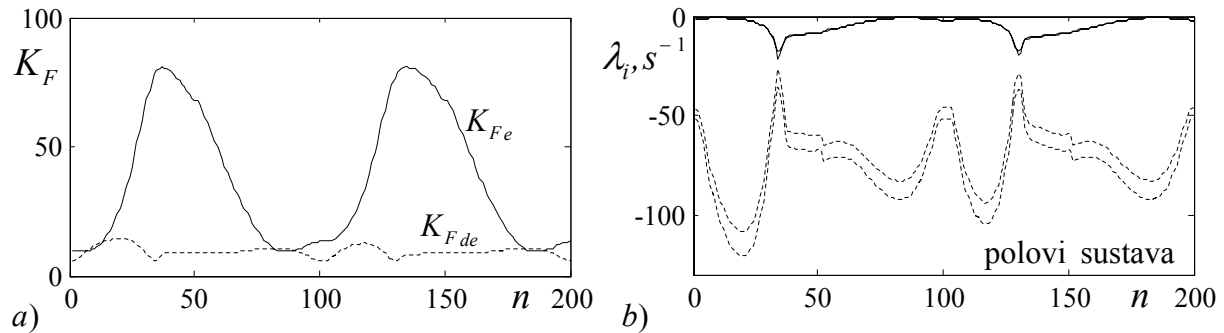
Slika 4.7 Prikaz nivo upravljačkih krivulja $u_F = \text{const}$ u faznoj ravnini stanja početno ugođenog **PD-PNAR**-a, na početku a) i na kraju procesa adaptiranja nakon 60 iteracija b).



Slika 4.8 Prikaz postignute pozicije a) i brzine b) početno ugođenog **PD-PNAR**-a, ($K_{np}=10$, $K_{nv}=6$) prije početka (-d) i nakon završetka procesa adaptiranja (-c)


Naglašeno je nelinearno djelovanje neizrazitog analitičkog regulatora kod malih vrijednosti pogreške pozicije i brzine. Postignute vrijednosti pozicije i brzine nakon 60 promjena referenci, odnosno na kraju provedenog procesa adaptiranja izrazima (4.8, 4.17, 4.19 i 4.23) prikazane su dijagramima na slici 4.8. Provedenim postupkom adaptiranja slobodnih parametara **PD-PNAR**-

a, oblikovana je karakteristična upravljačka površina čije se neizrazito djelovanje kod malih vrijednosti pogreške može uočiti na prikazanoj faznoj ravnini (slika 4.7b), a do punog izražaja dolazi kroz promjene neizrazitih vrijednosti pojačanja $K_F(n)$ u zavisnosti o pogreškama pozicije i brzine kao ulaznih varijabli **PD-PNAR**-a (slika 4.9a).




Slika 4.9 Promjene neizrazitih vrijednosti pojačanja pozicije (K_{Fe} , V/rad) i brzine (K_{Fde} , Vs/rad) a), te prikaz promjena karakterističnih vrijednosti sustava λ_i ($i=1,2,3,4$) u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini po završetku procesa adaptiranja b).

Bilo pozitivan ili negativan prirast pogreške pozicije (slika 4.4a) i brzine (slika 4.4b) dovodi do pozitivnog prirasta, odnosno povećanja apsolutnih vrijednosti neizrazitog pojačanja pozicije K_{Fe} i brzine K_{Fde} , što utječe na udaljavanje polova sustava od ishodišta u negativnoj Gausovoj kompleksnoj poluravnini (slika 4.9b). U tom slučaju kažemo da pri povećanju prirasta pogreške pozicije i brzine dolazi do povećanja asimptotske stabilnosti dinamičkog sustava, što je osnovna karakteristika prve klase **PD-PNAR**-a u progresivnom modu rada. Promjena vrijednosti integrala kvadrata pogreške u diskretnom području (4.18) pozicije ISE_e i brzine ISE_{de} po iteracijama (promjenama reference) pri procesu adaptiranja slobodnih parametara prikazan je dijagramima na slici 4.10 i 4.11.




Slika 4.10 Prikaz vrijednosti ISE_e (3.18) pozicije po iteracijama (promjenama reference) pri procesu adaptiranja slobodnih parametara **PD-PNAR**-a.




Slika 4.11 Prikaz ISE_{de} (3.18) brzine po iteracijama (promjenama reference) pri procesu adaptiranja slobodnih parametara **PD-PNAR-a**.

Pri zadanoj željenoj vrijednosti Integrala kvadrata pogreške (ISE), brzina adaptacije prvenstveno zavisi o izboru koeficijenta obučavanja koji je dan konstantama A_F i A_β . Za veće vrijednosti odabranih faktora obučavanja brzina postupka organiziranja biti će veća, ali će zato sustav biti bliži granici nestabilnosti. Kako su zahtjevi za brzinom procesa adaptiranja slobodnih parametara i stabilnosti algoritma podešavanja u kontradikciji preporuča se odabrati takve koeficijente obučavanja koji će na račun brzine adaptiranja osigurati veće područje stabilnosti dinamičkog sustava pri procesu adaptacije. Na brzinu podešavanja slobodnih parametara utječu i koeficijenti zamaha α čija se vrijednosti kreću između 0,1-0,9. Ako zamah držimo konstantnim iznosima, onda promjenom vrijednosti faktora obučavanja utječemo na brzinu procesa adaptacije kao što je to prikazano dijagramom na slici 4.12.



Slika 4.12 Promjene vrijednosti $ISE_e=0,01$ kao kriterija zaustavljanja procesa adaptiranja za različite vrijednosti faktora obučavanja

- (a)- $A_{Fe}=0,16$; $A_{Fde}=0,14$; $A_{\beta e}=0,67$; $A_{\beta de}=0,97$;
- (b)- $A_{Fe}=0,044$; $A_{Fde}=0,045$; $A_{\beta e}=0,184$; $A_{\beta de}=0,31$;
- (c)- $A_{Fe}=0,022$; $A_{Fde}=0,03$; $A_{\beta e}=0,092$; $A_{\beta de}=0,21$;
- (d)- $A_{Fe}=0,014$; $A_{Fde}=0,02$; $A_{\beta e}=0,06$; $A_{\beta de}=0,14$.



Slika 4.13 Promjena vrijednosti ISE_{de} po iteracijama (promjenama referenci) pri procesu adaptiranja za različite vrijednosti faktora obučavanja:

- (a)- $A_{Fe}=0,16$; $A_{Fde}=0,14$; $A_{\beta e}=0,67$; $A_{\beta de}=0,97$;
 (b)- $A_{Fe}=0,044$; $A_{Fde}=0,045$; $A_{\beta e}=0,184$; $A_{\beta de}=0,31$;
 (c)- $A_{Fe}=0,022$; $A_{Fde}=0,03$; $A_{\beta e}=0,092$; $A_{\beta de}=0,21$;
 (d)- $A_{Fe}=0,014$; $A_{Fde}=0,02$; $A_{\beta e}=0,06$; $A_{\beta de}=0,14$.


Kao kriterij zaustavljanja procesa adaptiranja definira se vrijednost diskretnog integrala kvadratne pogreške pozicije $ISE_e=0,01$. Iz dijagrama je vidljivo da je za dostizanje te vrijednosti kod faktora obučavanja (d) potrebno gotovo tri puta više vremena nego kod faktora obučavanja (b). Promjena vrijednosti diskretnog integrala kvadratne pogreške brzine pri različitim vrijednostima faktora obučavanja prikazana je dijagramima na slici 4.13.

4.2 Rezultati simulacije vođenja mobilnog robota referentnom putanjom složenog oblika u prostoru upravljanih koordinata

Prethodno izloženim postupkom podešavanja početno ugođenog **PD-PNAR**-a (3.24), provodi se proces adaptiranja njegovih slobodnih parametara u **OFF**-line modu rada pri vođenju mobilnog robota referentnom putanjom složenijeg oblika (slika 3.8). Uvođenjem integralnog kriterija kvadrata pogreške pozicije (3.18) $ISE_e=0,033$, proces adaptiranja uz parametre navedene tablicom 4.1 zaustavlja se nakon 27 promjena referenci u oba smjera, s konačnim vrijednostima slobodnih parametara:

$$F_e=23, \quad \beta_e=0,0007, \quad F_{de}=20, \quad \beta_{de}=0,0072. \quad (4.26)$$


Na slici 4.14 prikazane su pogreške pozicije lijeve i desne upravljane koordinate prije početka procesa adaptiranja (a) i nakon završetka procesa adaptiranja (b). Iz prikazanih grafova vidi se da je maksimalna vrijednost pogreške sa početka procesa adaptiranja smanjena gotovo šest puta.



Slika 4.14 Pogreška pozicije pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku *a*) i nakon procesa adaptiranja slobodnih parametara **PD-PNAR**-a *b*).


Veće vrijednosti pogreške pozicije i brzine (slika 4.15) odgovaraju oštrijim režimima gibanja mobilnog robota, kao što su veći kutovi skretanja. To je osobito izraženo kod pozicija i brzina početno podešenog **PD-PNAR**-a (*a*), dok je kod **PD-PNAR**-a, nakon procesa adaptiranja zbog neizrazitog djelovanja ta razlika manje naglašena (*b*). Zbog postojanja predupravljanja (slika 2.17, $M=0$) ili integralnog djelovanja (slika 2.17, $M=1$), svako izlazno odstupanje pozicije i brzine od nominalne vrijednosti dovodi do promjene položaja centra izlaznih neizrazitih skupova izlazne pogreške pozicije i brzine od nulte vrijednosti, pri čemu vrijedi

$$\text{sign}(Y_e) = -\text{sign}(\Delta q), \quad \text{sign}(Y_{de}) = -\text{sign}(\Delta \dot{q}) \quad (4.27)$$




Slika 4.15 Pogreška brzine pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku *a*) i nakon procesa adaptiranja slobodnih parametara **PD-PNAR**-a *b*).


Sa ciljem kompenziranja izlazne pogreške položaja i brzine pozitivnom prirastu pogreške pozicije i brzine mora odgovarati negativan prirast položaja centra izlaznog neizrazitog skupa i obrnuto. To se lijepo vidi na slijedećim dijagramima (slike 4.16-17).



Slika 4.16 Položaji centara izlaznih neizrazitih skupova pogreške pozicije Y_e pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku *a*) i nakon procesa adaptiranja slobodnih parametara **PD-PNAR-a** *b*).




Slika 4.17 Položaji centara izlaznih neizrazitih skupova pogreške brzine Y_{de} pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku *a*) i nakon procesa adaptiranja slobodnih parametara **PD-PNAR-a** *b*).




Slika 4.18 Neizrazita upravljačka veličina $u_F(n)$ servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8) na početku *a*) i nakon procesa adaptiranja slobodnih parametara **PD-PNAR-a** *b*).

Položaji centara izlaznih neizrazitih skupova pogreške pozicije (slika 4.16) i brzine (slika 4.17) izoštravaju se procesom adaptiranja (a), odnosno skupljaju oko nukleusa položaja centra neizrazitog skupa najvećeg utjecaja. Izlaznoj neizrazitoj upravljačkoj varijabli $u_F(n)$, po normaliziranim vremenski diskretnim koracima (n) doprinose položaji centara izlaznih neizrazitih skupova pogreške pozicije Y_e i brzine Y_{de} . Dijagramom na slici 4.18 prikazane su neizrazite upravljačke varijable servomotora lijevog i desnog pogonskog kotača na početku (a) i na kraju procesa adaptiranja (b).




Slika 4.19 Promjena neizrazite upravljačke veličine $\Delta u_F(n)$ nakon procesa adaptiranja u odnosu na početno ugođeni **PD-PNAR** servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8).

Zbog bolje razlučivosti neizrazitog djelovanja upravljačke varijable dijagramom na slici 4.19 nakon procesa adaptiranja prikazane su promjene neizrazite upravljačke varijable $\Delta u_F(n)$ servomotora lijevog i desnog pogonskog kotača u odnosu na početno ugođen **PD-PNAR**.




Slika 4.20 Vrijednosti neizrazitih pojačanja pozicije K_{Fe} (V/rad) i brzine K_{Fde} (Vs/rad) početno ugođenog **PD-PNAR**-a servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8).

Pri vođenju mobilnog robota zadanom referentnom putanjom (slika 3.8) prikazane su neizrazite vrijednosti pojačanja pozicije i brzine početno podešenog neizrazitog analitičkog regulatora (slika 4.20) s parametrima $K_{np}=10$ i $K_{nv}=6$ po normaliziranim vremenski diskretnim koracima (n). Po završetku postupka adaptiranja **PD-PNAR** je u stanju maksimalne pobuđenosti, odnosno najvećeg stupnja neizrazitog djelovanja. Njegovo nelinearno djelovanje se očituje kroz neizrazite vrijednosti pojačanja (slika 4.21-22) koja se sada ovisno o pogrešci pozicije i brzine povećavaju gotovo osam puta.




slika 4.21 Vrijednosti neizrazitih pojačanja pozicije (K_{Fe}) nakon procesa adaptiranja slobodnih parametara **PD-PNAR**-a servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8).




Slika 4.22 Vrijednosti neizrazitih pojačanja brzine (K_{Fde}) nakon procesa adaptiranja slobodnih parametara **PD-PNAR**-a servosustava pogonskih kotača pri vođenju mobilnog robota referentnom putanjom (slika 3.8).

Djelovanje **PD-PNAR**-a očituje se kod prijelaznih procesa koji dolaze do izražaja kod skretanja odnosno gibanja mobilnog robota pri prijelazu sa jednog na drugi dio pravocrtnog segmenta globalne referentne trajektorije, dok pri stacionarnom gibanju pravocrtnim dijelovima segmenata izostaje neizrazito djelovanje **PD-PNAR**-a u smislu nepromijenjenih vrijednosti neizrazitog

pojačanja pozicije (slika 3.1.8) i brzine (slika 3.1.9). Dakle većim vrijednostima pogreške pozicije i brzine odgovaraju redom i veće neizrazite vrijednosti pojačanja pozicije K_{Fe} i brzine K_{Fde} i obrnuto. Povećanje vrijednosti neizrazitih pojačanja u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini (slika 1.6), osim smanjenja vrijednosti pogreški (slika 4.14-15) dovodi i do povećanja stupnja asimptotske stabilnosti dinamičkog sustava. Povećani stupanj asimptotske stabilnosti dinamičkog sustava, prvenstveno se očituje kroz pomicanje polova u S-ravnini više ulijevo. Stoga su dijagramom (slika 4.23) prikazani korijeni dinamičkog sustava pri zatvorenim regulacijskim petljama pozicije i brzine kod početno podešenog **PD-PNAR**-a, dok su položaji polova nakon procesa adaptiranja pri vođenju mobilnog robota referentnom trajektorijom (slika 2.6) prikazani dijagramom (slika 4.24).



Slika 4.23 Polovi dinamičkog sustava mobilnog robota s implementiranim početno ugođenim **PD-PNAR**-om u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini (slika 2.17, $M=0$) pri vođenju mobilnog robota referentnom putanjom (slika 3.8).



Slika 4.24 Polovi dinamičkog sustava nakon procesa adaptiranja slobodnih parametara **PD-PNAR**-a u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini (slika 2.17, $M=0$) pri vođenju mobilnog robota referentnom putanjom (slika 3.8).

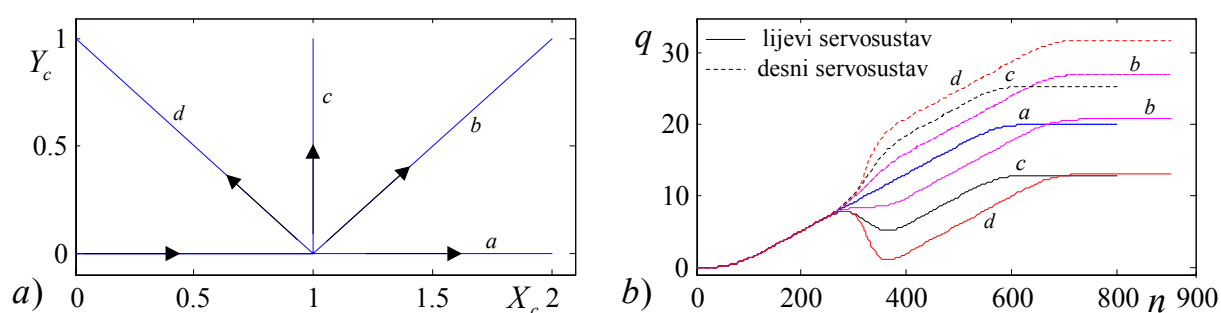
4.3 Usporedba djelovanja PD-PNAR-a sa klasičnim PD-regulatorom

Na nivou i -tog stupnja slobode gibanja definirana je upravljačka varijabla s implementiranim klasičnim linearnim PD zakonom upravljanja (2.54) s pojačanjem predupravljanja P .

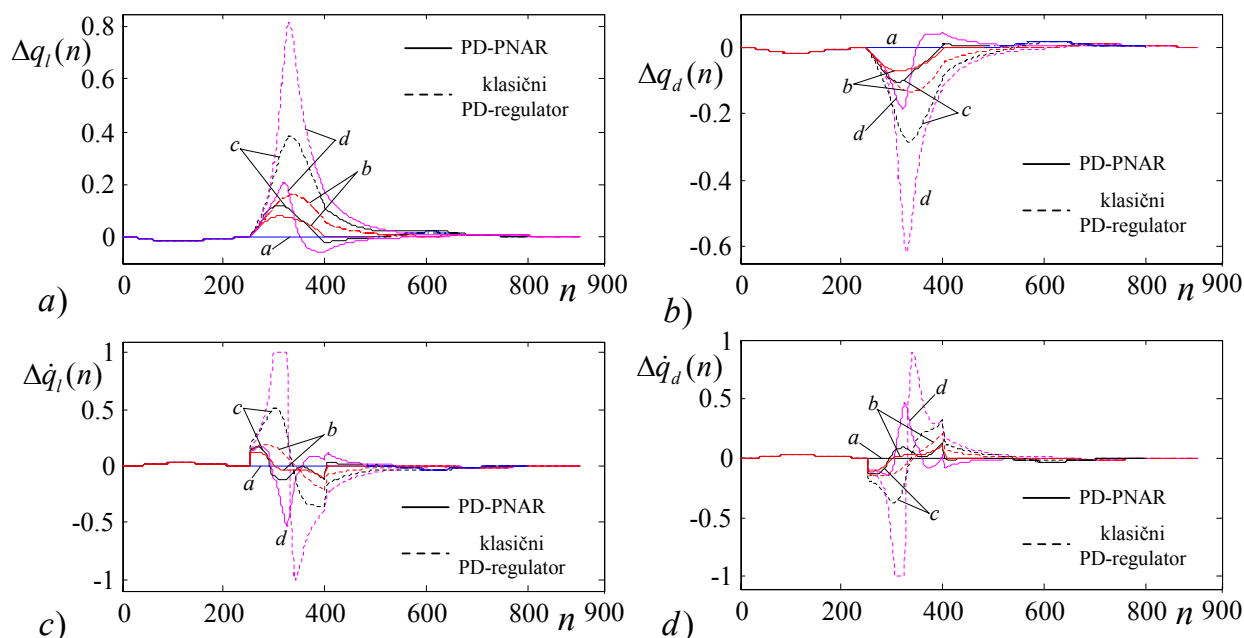
$$(u_r)_i = -K_{pi}\Delta q_i - K_{vi}\Delta \dot{q}_i + P_i(u_n)_i, \quad i=1,2, \quad (4.28)$$

dok je upravljačka varijabla sa implementiranim **PD-PNAR**-om (2.79, $M=0$) jednaka


$$(u_r)_i = \Psi_i(e, de, F, \beta) + P_i(u_n)_i, \quad i=1,2. \quad (4.29)$$



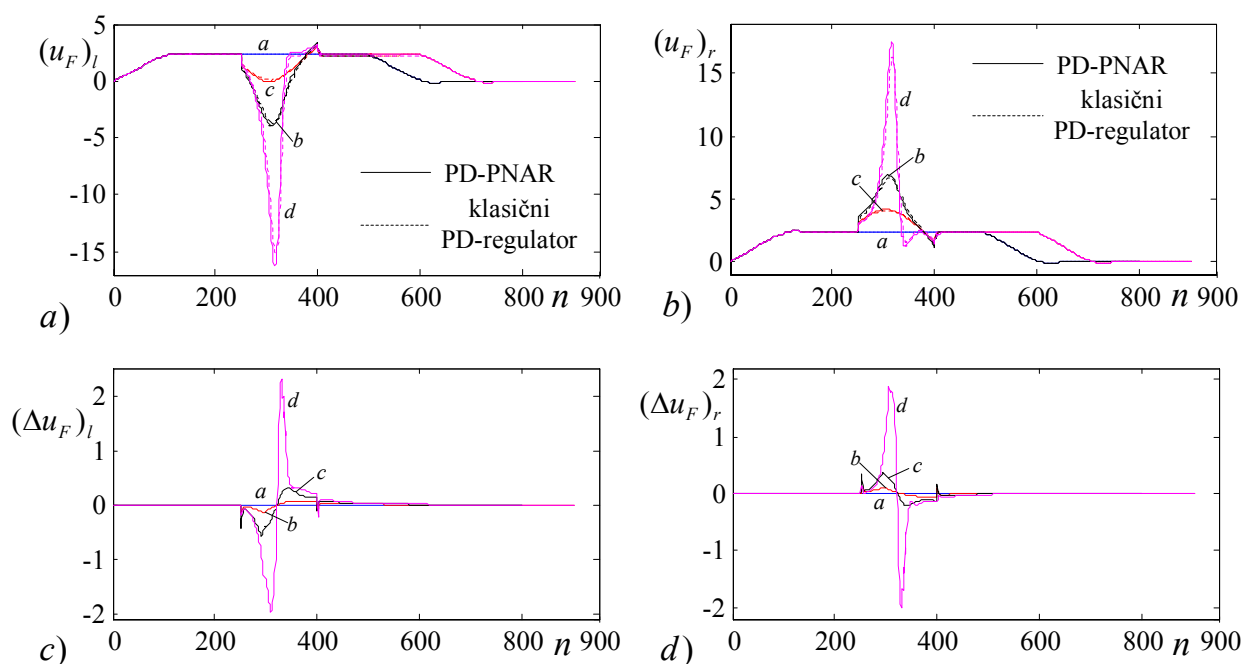
Slika 4.25 Ostvarene trajektorije u prostoru unutarnjih upravljanih koordinata b), pri gibanja mobilnog robota zadanim referentnim putanjama u vanjskim koordinatama a).



Slika 4.26 Pogreške pozicije Δq a), b) i brzine $\Delta \dot{q}$ c), d) servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota različitim zadanim referentnim putanjama (a,b,c i d) sa slike 4.25a.




Slika 4.27 Položaji centara izlaznih neizrazitih skupova pogreške pozicije Y_e a), b) i brzine Y_{de} c), d) servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota različitim zadanim referentnim putanjama (a,b,c i d) sa slike 4.25a.




Slika 4.28 Upravljačka varijabla u_F , a), b) servosustava lijevog i desnog pogonskog kotača sa implementiranim **PD-PNAR**-om i klasičnim **PD** regulatorom, te promjene upravljačke varijable Δu_F c) i d) u odnosu na dinamički sustav s implementiranim klasičnim **PD**-regulatorom pri vođenju mobilnog robota različitim zadanim referentnim putanjama (a,b,c i d) sa slike 4.25a.

Uz definirane vrijednosti pojačanja $K_P=10$, $K_V=6$, $P=2,27$ i slobodne parametre **PD-PNAR**-a dobivene adaptiranjem (4.26), uspoređuju se zakoni upravljanja integralnim kriterijem kvadrata pogreške pozicije i brzine (4.18), pri vođenju mobilnog robota različitim zadanim referentnim putanjama u vanjskim (slika 4.25a), odnosno unutarnjim koordinatama (slika 4.25b). Izlazne pogreške pozicije i brzine servosustava lijevog i desnog pogonskog kotača većeg su iznosa kod zahtjevnijih režima vođenja mobilnog robota referentnim putanjama (slika 4.25) i prikazani su dijagramima na slici 4.26a-d. Kod dinamičkog sustava s implementiranim **PD-PNAR**-om većim iznosima pogreške odgovaraju također i veći iznosi položaja centara izlaznih neizrazitih skupova pogreške pozicije i brzine (slika 4.27a-d) pri čemu vrijede izrazi (4.27). Za ostvarivanje većih kutova skretanja potrebne su i veće vrijednosti upravljačkih varijabli (4.28-29), (slika 4.28a-b). Neizrazito djelovanje **PD-PNAR**-a naročito dolazi do izražaja kod zahtjevnijih zadanih referentnih putanja (slika 4.25) s većim kutom skretanja kod kojih promjene upravljačke varijable uslijed neizrazitog djelovanja u odnosu na upravljačku varijablu klasičnog linearnog **PD**-zakona upravljanja je prikazana dijagramima na slici 4.28c-d. Veći iznosi upravljačke varijable (4.29) uslijed neizrazitog djelovanja pri oštrijim skretanjima referentnim putanjama (slika 4.25a) posljedice su znatno povećanih vrijednosti neizrazitog pojačanja pozicije (K_{Fe}) i brzine (K_{Fde}) (slika 4.29a-d) uslijed progresivnog moda rada **PNAR**-a ($\eta < 0$).



Slika 4.29 Vrijednosti neizrazitog pojačanja pozicije (K_{Fe}) a), b) i brzine (K_{Fde}) c), d) servosustava lijevog i desnog pogonskog kotača pri vođenju mobilnog robota različitim zadanim referentnim putanjama (a,b,c i d), (slika 4.25a).

Polovi dinamičkog sustava mobilnog robota s implementiranim klasičnim linearnim **PD**-zakonom upravljanja vrijednosti $\lambda_1=-52.0076$, $\lambda_2=-46.6095$, $\lambda_3=-1.8932$ i $\lambda_4=-1.9012$ se uslijed neizrazitog djelovanja **PD-PNAR**-a pri oštrijim skretanjima zadanih referentnih putanja (slika 4.25), znatno mijenjaju, pomičući se više ulijevo u Gausovoj kompleksnoj ravnini i doprinoseći na taj način povećanom stupnju asimptotske stabilnosti dinamičkog sustava u uvjetima zatvorenih regulacijskih petlji pozicije i brzine (slika 4.30a-d).



Slika 4.30 Promjena polova u uvjetima zatvorenih regulacijskih petlji po poziciji i brzini, (slika 2.17, $M=0$) pri vođenju mobilnog robota sa **PD-PNAR**-om pri različitim zadanim referentnim putanjama a) (-a), b) (-b), c) (-c) i d) (-d), slika 4.25a.

	Klasični linearni PD-regulator				PD-PNAR			
trajektorija	a	b	c	d	a	b	c	d
$(ISE_e)_1$	0,000648	0,0211	0,1005	0,2866	0,000622	0,005	0,0095	0,0169
$(ISE_e)_d$	0,000648	0,0158	0,0570	0,1447	0,000622	0,0046	0,0077	0,0122
$(ISE_{de})_1$	0,0016	0,3097	0,6719	1,2825	0,0016	0,0085	0,0166	0,0686
$(ISE_{de})_d$	0,0016	0,2639	0,4947	0,9583	0,0016	0,0069	0,0117	0,0513

Tablica 4.2 Vrijednosti **ISE**, pri vođenju mobilnog robota različitim referentnim trajektorijama (slika 4.25) sa implementiranim zakonima upravljanja (4.28-29)

Rezultati primjene integralnog kriterija kvadrata pogreške **ISE**, pri vođenju mobilnog robota različitim referentnim trajektorijama (slika 4.25) sa implementiranim zakonima upravljanja (4.28-29) dani su u obliku tablice 4.2. Na kraju disertacije (Prilog 5) priložen je program pisan u tehničkom okruženju programskog paketa **MATLAB** koji vrši adaptiranje slobodnih parametara **PD-PNAR**-a pod nazivom *spnar.m*.

4.4 Stabilnost algoritma adaptiranja

Dinamički sustav mobilnog robota dan tripletom matrica (3.6), u vremenski kontinuiranom području [38, 40] može se opisati jednadžbom stanja i izlaza sustava u vremenski diskretnom području kako slijedi

$$\mathbf{X}(n+1) = \mathbf{A}_d \mathbf{X}(n) + \mathbf{B}_d \mathbf{U}(n), \quad \mathbf{Y}(n) = \mathbf{C}_d \mathbf{X}(n), \quad \mathbf{X}(n=0) = \mathbf{X}_0, \quad (4.30)$$

u kojima su s realnim stupčanim matricama $\mathbf{X} \in \mathbf{R}^n$, $\mathbf{Y} \in \mathbf{R}^p$ i $\mathbf{U} \in \mathbf{R}^m$, redom dani apsolutni vektori stanja, izlaza i ulaza u sustav odgovarajućih dimenzija n , p i m . Do idealnog egzaktnog diskretnog ekvivalenta, linearnom vremenski kontinuiranom matričnom tripletu (3.6) dolazi se matričnim jednadžbama

$$\mathbf{A}_d = \Phi(T_s) = e^{\mathbf{A}T_s}, \quad \mathbf{B}_d = [\Phi(T_s) - \Phi(0)]\mathbf{A}^{-1}\mathbf{B}, \quad \mathbf{C}_d = \mathbf{C}, \quad (4.31)$$

u kojima $\Phi(t)$ u zatvorenoj formi označava prijelaznu matricu, dobivenu inverznom Laplasovom (eng. Laplaceovom) transformacijom rezolventne matrice $(s\mathbf{I} - \mathbf{A})^{-1}$. Ako željenu dinamiku ulaza, stanja i izlaza dinamičkog sustava (4.30) redom označimo stupčanim matricama $\mathbf{X}_n(n) \in \mathbf{R}^n$, $\mathbf{Y}_n(n) \in \mathbf{R}^p$ i $\mathbf{U}_n(n) \in \mathbf{R}^m$ dolazi se do željene (nominalne) dinamike određene jednadžbom stanja i izlaza sustava

$$\mathbf{X}_n(n+1) = \mathbf{A}_d \mathbf{X}_n(n) + \mathbf{B}_d \mathbf{U}_n(n), \quad \mathbf{Y}_n(n) = \mathbf{C}_d \mathbf{X}_n(n), \quad \mathbf{X}_n(t=0) = \mathbf{X}_0. \quad (4.32)$$

Unatoč djelovanju nominalne upravljačke varijable $\mathbf{U}_n(n)$ u realnom slučaju, djelovanjem vanjskog slučajnog poremećaja svedenog na ulaz kao $\Delta \mathbf{U}_p(n) = \mathbf{U}(n) - \mathbf{U}_n(n)$, redovito dolazi do odstupanja stanja $\Delta \mathbf{X}(n)$ i izlaza $\Delta \mathbf{Y}(n)$ sustava od željene dinamike

$$\Delta \mathbf{X}(n) = \mathbf{X}(n) - \mathbf{X}_n(n), \quad \Delta \mathbf{Y}(n) = \mathbf{Y}(n) - \mathbf{Y}_n(n), \quad (4.33)$$

zato vrijedi

$$\mathbf{X}(n+1) = \mathbf{A}_d \mathbf{X}(n) + \mathbf{B}_d [\mathbf{U}_n(n) + \Delta \mathbf{U}_p(n)], \quad \mathbf{Y}(n) = \mathbf{C}_d \mathbf{X}(n), \quad \mathbf{X}(n=0) = \mathbf{X}_0. \quad (4.34)$$

U svrhu smanjivanja nastale pogreške uvodi se dodatna upravljačka varijabla $\Delta \mathbf{U}_r(n)$, tako da se uz (4.32) dolazi do dinamičkog modela signala razlike odnosno dinamičkog modela odstupanja od željene trajektorije u obliku

$$\Delta \mathbf{X}(n+1) = \mathbf{A}_d \Delta \mathbf{X}(n) + \mathbf{B}_d [\Delta \mathbf{U}_r(n) + \Delta \mathbf{U}_p(n)] , \quad \Delta \mathbf{Y}(n) = \mathbf{C}_d \Delta \mathbf{X}(n) , \quad (4.35)$$

gdje $\Delta \mathbf{X}(n) \in \mathbf{R}^n$ i $\Delta \mathbf{Y}(n) \in \mathbf{R}^p$ redom predstavljaju vektore relativnog stanja i izlaza u odnosu na željena stanja i željeni izlaz dinamičkog sustava (4.30), s definiranim komponentama odstupanja vektora stanja

$$\Delta \mathbf{X}(n) = [\Delta x_1(n) \Delta x_2(n) \Delta x_3(n) \Delta x_4(n)]^T , \quad \Delta x_i(n) = [x_i(n) - x_{in}(n)] , \quad i=1,2, \dots, 4 . \quad (4.36)$$

U slučaju da je upravljačka varijabla (za koju općenito vrijedi $\text{sgn}[\Delta \mathbf{U}_r(n)] = -\text{sgn}[\Delta \mathbf{U}_p(n)]$) po iznosu upravo jednaka poremećaju $\Delta \mathbf{U}_p(n)$, ne postoji odstupanje stanja $\Delta \mathbf{X}(n)=0$ i izlaza $\Delta \mathbf{Y}(n)=0$ sustava od željenih nominalnih iznosa. U tom idealnom slučaju ako ne postoji odstupanje početnog stanja od željenog iznosa mobilni robot se giba željenom referentnom trajektorijom bez odstupanja. Kako u realnom slučaju upravljačka varijabla $\Delta \mathbf{U}_r(n)$ nikada ne može točno procijeniti vanjski slučajni poremećaj $\Delta \mathbf{U}_p(n)$ i/ili zbog nedovoljno točnog dinamičkog modela redovito se javljaju odstupanja. Proces adaptiranja slobodnih parametara **PNAR**-a vrši se u **OFF**-line modu rada pri čemu izostaje vanjski poremećaj $\Delta \mathbf{U}_p(n)=0$. Na početku postupka adaptiranja početnim ugađanjem **PD-PNAR**-a, dinamički sustav mobilnog robota zajedno sa implementiranim **PD-PNAR**-om u uvjetima zatvorenih regulacijskih petlji po stanjima odnosno poziciji i brzini, doveden je u stabilno (ravnotežno) stanje. Po završetku adaptiranja slobodnih parametara **PD-PNAR**-a vidljivo je poboljšanje dinamike (kretanja) dinamičkog sustava. Tako u idealnom slučaju za razliku od onih danih izrazom (4.32), ulaz, stanje i izlaz dinamičkog sustava se redom označava stupčanim matricama $\mathbf{X}_n^*(n) \in \mathbf{R}^n$, $\mathbf{Y}_n^*(n) \in \mathbf{R}^p$ i $\mathbf{U}_n^*(n) \in \mathbf{R}^m$, dok izrazi:

$$\Delta \mathbf{X}(n+1) = \mathbf{A}_d \Delta \mathbf{X}(n) + \mathbf{B}_d \Delta \mathbf{U}_r(n) , \quad \Delta \mathbf{Y}(n) = \mathbf{C}_d \Delta \mathbf{X}(n) , \quad \Delta \mathbf{X}(n=0) = \Delta \mathbf{X}_0 , \quad (4.37)$$

za razliku od (4.35) sada predstavljaju jednadžbe odstupanja stanja i izlaza sustava od idealnog željenog stanja i izlaza postignutog adaptiranjem slobodnih parametara **PD-PNAR**-a.


$$\mathbf{X}_n^*(n+1) = \mathbf{A}_d \mathbf{X}_n^*(n) + \mathbf{B}_d \mathbf{U}_n^*(n) , \quad \mathbf{Y}_n^*(n) = \mathbf{C}_d \mathbf{X}_n^*(n) , \quad \mathbf{X}_n^*(n=0) = \mathbf{X}_0^* . \quad (4.38)$$

U tom slučaju se promjena upravljačke varijable $\Delta \mathbf{U}_r(n)$ u izrazu (4.37) tretira kao dodatna promjena upravljačke varijable $\Delta \mathbf{U}_r(n) = \Delta \mathbf{U}_F(n)$ generirana od strane algoritma adaptiranja (4.8) sa osnovnim ciljem smanjenja pogreške pozicije i brzine (4.11), odnosno postizanja određene vrijednosti funkcije cilja (4.10) definirane željenom vrijednosti *ISE*-kriterija u diskretnom obliku (4.18). Pri tome n -dimenzijonalnom prostoru treba da vrijedi $\lim_{t \rightarrow \infty} \|\Delta \mathbf{x}(t)\| = 0$, odnosno

prestankom rada algoritma adaptiranja vrijedi odnos između normi $\|\Delta \mathbf{x}^*(n)\| < \|\Delta \mathbf{x}(n)\|$.

Zadržavanje trajektorije pogreške $\Delta \mathbf{x}^*(n)$ unutar hiper sfere polumjera r_2 n -dimenzijalnog

prostora (slika 4.31a) zadatak je algoritma adaptiranja. Pri tome se oblikuje karakteristična površina odnosno neizrazita upravljačka varijabla $u_n^*(n)$ kod koje nastaje pogreška $\Delta x^*(n)$ (slika 4.31b). Postupkom adaptiranja potrebno je ostvariti stabilno približavanje trajektorije stanja sustava $\mathbf{X}(n)$, trajektoriji $\mathbf{X}_n^*(n)$ postignutoj nakon postupka adaptiranja. Pritom se je norma pogreške $\|\Delta \mathbf{x}(n)\|$, ograničena u n -dimenzijonalnom prostoru hiper sferom polumjera r_3 , postupkom adaptiranja smanjila $\|\Delta \mathbf{x}^*(n)\|$, zadržavajući se unutar hiper sfere polumjera r_2 (slika 4.31).



Slika 4.31 Prikaz gibanja norme trajektorije pogreške u n -dimenzijonalnom prostoru prije $\|\Delta \mathbf{x}(n)\|$ i poslije procesa adaptiranja $\|\Delta \mathbf{x}^*(n)\|$ a), te prikazivanje gibanja upravljačke varijable prije $u_r(n)$ i nakon procesa adaptiranja slobodnih parametara **PD-PNAR-a** b).

Ukupna upravljačka varijabla dinamičkog sustava mobilnog robota sa implementiranim početno ugođenim **PD-PNAR-om**

$$u_r(n+1) = \Psi(e, de, F_o, \beta_o, n) + Pu_n(n) \quad , \quad (4.39)$$

po završetku postupka adaptiranja postaje

$$u_r^*(n+1) = \Psi^*(e, de, F^*, \beta^*, n) + Pu_n(n) \quad , \quad (4.40)$$

dok je potrebni prirast upravljačke varijable po normaliziranim vremenski diskretnim koracima (n) u postupku adaptiranja prvenstveno određen uslijed promjena slobodnih parametara **PD-PNAR-a**. Dinamika promjene slobodnih parametara mora biti takva da osigura stabilnost procesa adaptiranja odnosno stabilnost objekta regulacije zajedno sa implementiranim algoritmom adaptiranja (slika 4.32). Potrebno je stoga procijeniti ograničenja prilikom izbora faktora obučavanja A_β i A_F po izlaznoj pogrešci pozicije Δx_i i brzine Δx_{n+i} ($i=1,2$.) da bi se to osiguralo. Pritom općenit izraz za promjenu parametara po gradijentu pogreške (4.22) zapisuje se u jednostavnijem izvornom obliku

$$\Delta \mathcal{G}(n) = -(\eta_g \Theta_g \Delta x)_{(n)} \quad n=1,2,\dots,N. \quad (4.41)$$

To je moguće učiniti pošto su faktori obučavanja η_g definirani kao sporo promjenjive funkcije vremena pri čemu se utjecaj drugog pribrojnika (4.22) može, kod integralnog kriterija kvadrata pogreške (4.18), približno nadomjestiti nešto povećanim iznosima početnih vrijednosti ISE_g kriterija. Uz prethodni izraz dodatnu upravljačku varijablu $[\Delta u_r(n)]_i$, prouzročenu promjenom slobodnih parametara procesom adaptacije (4.8), za i -ti stupanj slobode gibanja, zapisujemo u slijedećem obliku

$$(\Delta u_r)_i = (\Delta u_F)_i = -(\eta_{Fe} \Theta_{Fe}^2 + \eta_{\beta e} \Theta_{\beta e}^2)_{(n)}^{(i)} \Delta q_i - (\eta_{Fde} \Theta_{Fde}^2 + \eta_{\beta de} \Theta_{\beta de}^2)_{(n)}^{(i)} \Delta q_{n+i}, \quad i=1,2, \quad (4.42)$$

buduću da vrijedi $\Delta \mathbf{X}(n) = \Delta \mathbf{q}(n) = [\Delta q_1 \Delta q_2 \Delta \dot{q}_1 \Delta \dot{q}_2]^T$ i $\Delta \mathbf{U}_r(n) = [(\Delta u_r)_1 (\Delta u_r)_2]^T$. Prethodni izraz u matričnom obliku glasi

$$\Delta \mathbf{U}_r(n) = \mathbf{\Omega} \Delta \mathbf{X}(n) = \begin{bmatrix} \Omega_{11}(n) & 0 & \Omega_{13}(n) & 0 \\ 0 & \Omega_{22}(n) & 0 & \Omega_{24}(n) \end{bmatrix} \Delta \mathbf{X}(n) \quad (4.43)$$

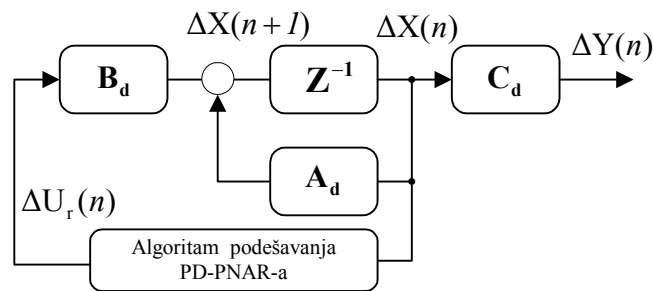
gdje za i -ti stupanj slobode gibanja elementi matrice $\mathbf{\Omega}$ u normaliziranom vremenski diskretnom koraku (n) iznose

$$\Omega_{i(i)}(n) = -(\eta_{Fe} \Theta_{Fe}^2 + \eta_{\beta e} \Theta_{\beta e}^2)_{(n)}^{(i)}, \quad \Omega_{i(2+i)}(n) = -(\eta_{Fde} \Theta_{Fde}^2 + \eta_{\beta de} \Theta_{\beta de}^2)_{(n)}^{(i)}. \quad (4.44)$$

Uvrštavanjem izraza (4.43) u (4.37) dolazi se do dinamičkog modela signala razlike

$$\Delta \mathbf{X}(n+1) = [\mathbf{A}_d + \mathbf{B}_d \mathbf{\Omega}] \Delta \mathbf{X}(n), \quad \Delta \mathbf{X}(n=0) = \Delta \mathbf{X}_0 \quad (4.45)$$

koji je prikazan na (slici 4.32).



Slika 4.32 *Struktura modela signala razlike pri postupku adaptiranja slobodnih parametara PD-PNAR-a.*

Valja uočiti da su elementi (4.44) matrice $\mathbf{\Omega}$ vremenski varijabilni. Definiranjem približnog diskretnog ekvivalenta linearnom vremenski kontinuiranom sustavu (3.6) matričnim tripletom

$$\mathbf{A}_d = [\mathbf{I} + T_s \mathbf{A}], \quad \mathbf{B}_d = T_s \mathbf{B}, \quad \mathbf{C}_d = \mathbf{C}, \quad (4.46)$$

danim prvom Ojlerovom varijantom numeričke integracije [58,59,87], dolazi se do vremenski varijabilnih koeficijenata karakterističnog polinoma $K(z) = \det[\mathbf{zI} - \mathbf{A}_d - \mathbf{B}_d\mathbf{\Omega}]$ modela signala razlike (4.45) u diskretnom području:

$$\det \begin{bmatrix} z-1 & 0 & -T_s & 0 \\ 0 & z-1 & 0 & -T_s \\ -KR_{ii}\Omega_{11}T_s & KR_{ij}\Omega_{22}T_s & z-1+(KQ_{ii}-KR_{ii}\Omega_{13})T_s & (KR_{ij}\Omega_{24}-KQ_{ij})T_s \\ KR_{ij}\Omega_{11}T_s & -KR_{ii}\Omega_{22}T_s & (KR_{ij}\Omega_{13}-KQ_{ij})T_s & z-1+(KQ_{ii}-KR_{ii}\Omega_{24})T_s \end{bmatrix}. \quad (4.47)$$

Zbog složenosti strukture dane matrice koeficijenti karakteristične jednadžbe ukupnog modela signala razlike (odstupanja) neće biti razvijani u centralnom obliku na nivou svih stupnjeva slobode gibanja. Zbog relativno malih brzina gibanja mobilnog robota referentnom putanjom, postoji u dinamičkom smislu slabo sprezanje između pojedinih stupnjeva slobode gibanja, pri čemu su matrice koeficijenata \mathbf{A}_{di} i ulaza sustava \mathbf{B}_{di} dinamičkog modela servosustava na nivou i -tog stupnja slobode gibanja dane izrazima

$$\mathbf{A}_{di} = \begin{bmatrix} 1 & T_s \\ 0 & 1 - KQT_s \end{bmatrix}, \quad \mathbf{B}_{di} = \begin{bmatrix} 0 \\ KRT_s \end{bmatrix}. \quad (4.48)$$

Uz definirane vektore stanja $\mathbf{X}_i(n)$ i odstupanja $\Delta\mathbf{X}_i(n)$ i -tog stupnja slobode gibanja

$$\mathbf{X}_i(n) = [x_i \quad x_{n+i}]^T, \quad \Delta\mathbf{X}_i(n) = [\Delta x_i \quad \Delta x_{n+i}]^T, \quad (4.49)$$

dolazi se do dinamičkog modela odstupanja

$$\Delta\mathbf{X}_i(n+1) = \hat{\mathbf{A}}_{di}\Delta\mathbf{X}_i(n), \quad \Delta\mathbf{X}_i(n=0) = \Delta\mathbf{X}_{0i}, \quad (4.50)$$

u kojem matrica sustava $\hat{\mathbf{A}}_{di} = \mathbf{A}_{di} + \mathbf{B}_{di}\mathbf{\Omega}$, je dana svojim karakterističnim polinom $K(z)$

$$K(z) = \det \hat{\mathbf{A}}_{di} = \det \begin{bmatrix} z-1 & -T_s \\ -KR\Omega_{11}T_s & z-1+(KQ-KR\Omega_{13})T_s \end{bmatrix}, \quad (4.51)$$

odnosno karakterističnom jednadžbom $a_2z^2+a_1z+a_0=0$,

$$z^2 + [(KQ - KR\Omega_{13})T_s - 2]z - [(KQ - KR\Omega_{13})T_s + KR\Omega_{11}T_s^2 - 1] = 0. \quad (4.52)$$

u kojoj su sa stajališta raspregnute dinamike lokalnih servosustava i -tog stupnja slobode gibanja elementi KR i KQ dani sa:

$$KR = \frac{K_{pu}C_M/R}{J_mN^2 + h_{ii}}, \quad KQ = \frac{C_eC_mN^2/R + D}{J_mN^2 + h_{ii}}. \quad (4.53)$$

Procjenu stabilnosti algoritma adaptiranja moguće je na zadovoljavajući način učiniti na lokalnom raspregnutom nivou servosustava i -tog stupnja slobode gibanja, pri čemu moduli vlastitih vrijednosti $|z_{1,2}|$ karakteristične jednadžbe (4.52) trebaju biti unutar jedinične kružnice Z -ravnine. Analogno Routh-ovom ili Hurwitz-ovom algebarskom kriteriju stabilnosti ovdje se

postavlja pojednostavljeni kriterij Schur-Cohna [58,80,87] poznat i kao Juryjev test stabilnosti koji se navodi nejednadžbama

$$K(z=1) > 0, \quad K(z=-1) > 0, \quad |a_0| < |a_2|, \quad (4.54)$$

iz kojih primjenom izraza (4.44 i 4.51) slijede uvjeti stabilnosti dani ograničenjima:

$$\Omega_{11} = \Theta_{Fe}^2 A_{Fe} e^{\frac{\sigma_{Fe} ISE_{Fe} - ISE}{ISE_{Fe}}} - \Theta_{\beta e}^2 \beta_e^2 \frac{\partial \beta_e}{\partial F_e} A_{\beta e} e^{\frac{\sigma_{\beta e} ISE_{\beta e} - ISE}{ISE_{\beta e}}} < 0, \quad (4.55)$$

$$\frac{KQ}{KR} + \frac{\Omega_{11} T_s}{2} - \frac{2}{KRT_s} < (\Theta_{Fde}^2 A_{Fde} e^{\frac{\sigma_{Fde} ISE_{Fde} - ISE}{ISE_{Fde}}} - \beta_{de}^2 \frac{\partial \beta_{de}}{\partial F_{de}} A_{\beta de} e^{\frac{\sigma_{\beta de} ISE_{\beta de} - ISE}{ISE_{\beta de}}} \Theta_{\beta de}^2) < \frac{KQ}{KR} + \Omega_{11} T_s. \quad (4.56)$$

Uzimajući pri izboru konstanti da je $\sigma_{Fe} = \sigma_{\beta e} = \sigma_1$, $\sigma_{Fde} = \sigma_{\beta de} = \sigma_2$, $ISE_{Fe} = ISE_{\beta e} = ISE_1$ i $ISE_{Fde} = ISE_{\beta de} = ISE_2$, odnosno da vrijedi odnos između faktora obučavanja

$$A_{Fe} = \varsigma_1 A_{\beta e}, \quad A_{Fde} = \varsigma_2 A_{\beta de}, \quad (4.57)$$

iz izraza (4.55-56) uz važeće izraze (2.71, 2.73 i 2.77) dolazimo do ograničenja potrebnih za osiguranje stabilnosti u konačnom obliku

$$\varsigma_1 < \beta_e^2 \left(\frac{\partial \beta_e}{\partial F_e} \right)^{-1}, \quad \nu - \left(\frac{2}{A_{\beta de} \Theta_{Fde}^2 KRT_s} \right) e^{-\sigma_2 \frac{ISE_2 - ISE}{ISE_2}} < \varsigma_2 < \nu + \left(\frac{\Omega_{11}(\varsigma_1) T_s}{2 A_{\beta de} \Theta_{Fde}^2} \right) e^{-\sigma_2 \frac{ISE_2 - ISE}{ISE_2}}, \quad (4.58)$$

gdje je s ν označena vremenski varijabilna granica intervala stabilnosti faktora obučavanja ς_2

$$\nu = \left(\frac{KQ}{A_{\beta de} \Theta_{Fde}^2 KR} + \frac{\Omega_{11}(\varsigma_1) T_s}{2 A_{\beta de} \Theta_{Fde}^2} \right) e^{-\sigma_2 \frac{ISE_2 - ISE}{ISE_2}} + \beta_{de}^2 \left(\frac{\partial \beta_{de}}{\partial F_{de}} \right)^{-1}. \quad (4.59)$$

Kako se radi o nelinearnom vremenski varijabilnom algoritmu adaptiranja dani uvjeti (4.58) trebaju biti zadovoljeni u svakom normaliziranom vremenski diskretnom koraku (n). Osjetljivost neizrazite upravljačke varijable na promjenu F i β parametra najveća, odnosno najmanja je na početku adaptiranja, a vrijednosti F i β parametara odnose se obrnuto proporcionalno sa osjetljivošću. Zbog toga je procjenu minimalne vrijednosti gornje i maksimalne vrijednosti donje granice omjera faktora obučavanja ς_1 i ς_2 najbolje vršiti na početku postupka adaptiranja, kada su granice intervala omjera faktora obučavanja ς_2 međusobno najbliže i kada približno vrijedi $ISE \approx ISE_2$, pri čemu se eksponencijalni član izraza (4.58-59) može izostaviti. U slučaju da omjer faktora obučavanja ς_1 teži svojoj graničnoj vrijednosti, granice intervala stabilnosti omjera ς_2 pomiču se više u desnu stranu. U svrhu osiguranja stabilnosti procesa adaptiranja, zbog usvojenih pojednostavljenja potrebno je odabrati omjere ς_1 i ς_2 nešto nižih vrijednosti od procijenjenih maksimalnih vrijednosti dobivenih simulacijom na elektroničkom računalu.

5. POBOLJŠANI NEIZRAZITI ANALITIČKI REGULATOR (PNAR) KAO NELINEARNI DISKRETNi (PD, PI I PID) REGULATOR

Regulacijsko djelovanje u izrazu (4.33) je dano prirastom neizrazite upravljačke varijable Δu_r , a očituje se procjenom iznosa poremećajne komponente Δu_p u najčešćem slučaju na osnovu izmjerenih vrijednosti izlaznih pogreški pozicije $\Delta q = -e$, brzine $\Delta \dot{q} = -\Delta e$ i ubrzanja $\Delta \ddot{q} = -\Delta^2 e$. Stoga su to ujedno i ulazne varijable neizrazitog analitičkog regulatora. Kod slijednog regulatora mobilnog robota definira se uređena trojka $\{e(n), \Delta e(n), u_r(n)\}$ koja ujedno predstavlja i karakterističnu upravljačku krivulju (faznu trajektoriju). Kod dinamičkih sustava kod kojih je izostao astatizam ili je potrebno udovoljiti zahtjevu za otklanjanje konstantnih nemjerljivih poremećaja, nužno je definirati uređenu trojku oblika $\{e(n), \Delta e(n), \Delta u_r(n)\}$. Na primjer kod pozicionih servosustava fazna upravljačka trajektorija definira se trojkom $\{e(n), \Delta e(n), u_r(n)\}$, odnosno uređenom trojkom $\{e(n), \Delta e(n), \Delta u_r(n)\}$ sa mogućnošću otklanjanja konstantnih nemjerljivih poremećaja. Kod brzinskog servosustava nužno je definirati trojku oblika $\{\Delta e(n), \Delta^2 e(n), \Delta u_r(n)\}$. Kod upravljanja objektima regulacije nultog astatizma ali složenije dinamičke strukture (npr. industrijski statički ili mobilni roboti) u svrhu otklanjanja nemjerljivih konstantnih poremećaja definira se uređena trojka $\{\Delta e(n), \Delta^2 e(n), \Delta^2 u_r(n)\}$ ili četvorka oblika $\{e(n), \Delta e(n), \Delta^2 e(n), \Delta^2 u_r(n)\}$. Za ulaznu varijablu umjesto prirasta pogreške moguće je definirati i prirast izlazne varijable $\Delta y(n)$. U tom slučaju kod pozicionog servosustava definiraju se uređene trojke redom $\{e(n), \Delta y(n), u_r(n)\}$ ili $\{e(n), \Delta y(n), \Delta u_r(n)\}$, odnosno kod brzinskog servosustava $\{\Delta e(n), \Delta^2 y(n), \Delta u_r(n)\}$ ili $\{\Delta e(n), \Delta^2 y(n), \Delta^2 u_r(n)\}$ ovisno o tome da li se zahtijeva otklanjanje nemjerljivih konstantnih poremećaja, odnosno da li sustav posjeduje astatizam ili ne. Familija karakterističnih (faznih) trajektorija upravljanja za različita stanja ulaznih varijabli neizrazitog analitičkog regulatora tvori neizrazitu (karakterističnu) upravljačku površinu [72] čiji oblik nelinearnim algoritmom prilagođavamo dinamičkim karakteristikama vođenog objekta regulacije [74], odnosno klasi tehničkih zadataka koje rješavamo. U nastavku će biti izloženi nelinearni **PD**, **PI** i **PID-PNAR** kao diskretni ekvivalenti klasičnim linearnim zakonima upravljanja tog tipa [75].

5.1 Nelinearni PD-PNAR i poremećaji tipa početnog uvjeta

Linearni **PD**-zakon upravljanja u kontinuiranom području ima oblik [74, 75]

$$u_r(t) = K_p e(t) + K_v \frac{de(t)}{dt} = K_p \left[e(t) + T_D \frac{de(t)}{dt} \right], \quad (5.1)$$

gdje su K_p , K_v i T_D redom konstante pojačanja regulatora (pozicije), brzine i derivacijska vremenska konstanta. U diskretnom području PD zakon upravljanja glasi

$$u_r(n) = K_p e(n) + K_v \Delta e(n) = K_p \left[e(n) + \frac{T_D}{T_s} \Delta e(n) \right], \quad (5.2)$$

gdje je T_s period uzorkovanja. Neizrazita upravljačka varijabla $u_F(n)$ generirana nelinearnim neizrazitim analitičkim **PD**-regulatorom (**PD-PNAR**-om) u svakom normaliziranom vremenski diskretnom koraku (n) daje se u općenitom obliku:

$$u_F(n+1) = \Psi(\underline{e}, \underline{de}, F, \beta, n), \quad (5.3)$$

gdje \underline{e} i \underline{de} redom označavaju normalizirane pogreške pozicije (e) i brzine (de) faktorima normiranja jednakim najvećoj apsolutnoj vrijednosti pogreške pozicije $|e|_{max}$ i brzine $|de|_{max}$ iz skupa danih mogućih vrijednosti $e \in \{e_{min}, \dots, e_{max}\}$ i $de \in \{de_{min}, \dots, de_{max}\}$. Upotrebom operatora zbrajanja moguće je nelinearnu funkciju Ψ sa stajališta karakterističnih funkcija danih položajem centara izlaznih neizrazitih skupova ulaznih varijabli $Y_e(\underline{e})$ i $Y_{de}(\underline{de})$ zapisati u raščlanjenom obliku (2.55)

$$u_F(n+1) = \Psi(\underline{e}, \underline{de}, F, \beta, n) = \phi_1(\underline{e}, \underline{de}) Y_e(\underline{e}) + \phi_2(\underline{e}, \underline{de}) Y_{de}(\underline{de}), \quad (5.4)$$

u kojem su sa ϕ_i ($i=1,2$) dane nelinearne težinske funkcije ulaznih varijabli. Ako aktivacijske funkcije u neizrazitim težinskim funkcijama (poglavlje 2) učestvuju sa malim stupnjem djelovanja onda iste postaju stalnice a prethodni izraz poprima jednostavniji i sa stajališta upravljačke regulacijske tehnike prihvatljiviji oblik:

$$u_F(n+1) = Y_e(e, n) + Y_{de}(de, n) = U_m \left[F_e \left(1 - \frac{\omega(e, n)}{n_e} \right) \text{sgn}(e) + F_{de} \left(1 - \frac{\omega(de, n)}{n_{de}} \right) \text{sgn}(de) \right], \quad (5.5)$$

ili sa čisto formalnog matematičkog stajališta pisano u obliku:

$$u_F(n+1) = K_{Fe}(e, n)e + K_{Fde}(de, n)\Delta e, \quad (5.6)$$

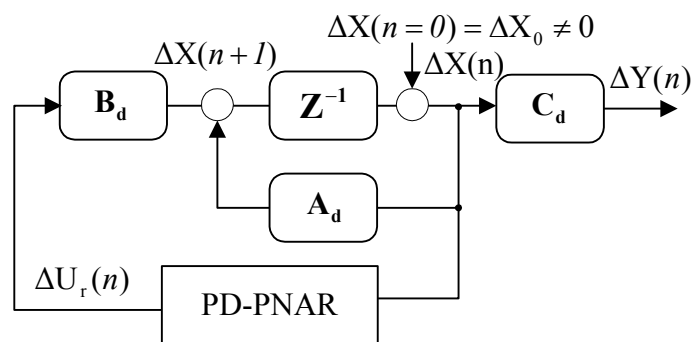
gdje K_{Fe} i K_{Fde} predstavljaju neizrazita pojačanja pozicije i brzine formalno dana u obliku

$$K_{Fe} = \frac{U_m F_e \left(1 - \frac{\omega(e, n)}{n_e} \right) \text{sign}(e)}{e}, \quad K_{Fde} = \frac{U_m F_{de} \left(1 - \frac{\omega(de, n)}{n_{de}} \right) \text{sign}(de)}{\Delta e}. \quad (5.7)$$

Kako se u općenitom slučaju neizrazita pojačanja dobivaju u pravilu kao omjeri položaja centara izlaznih neizrazitih skupova Y_j i j -te ulazne varijable, ona izražavaju statički tip nelinearnosti bez histereznog (relejnog) djelovanja koja su ovdje svjesno uvedena sa ciljem postizanja željenog ponašanja dinamičkog sustava. Statička nelinearnost je najčešći oblik nelinearnosti svojstven realnim sustavima u praksi, ponekad uvjetovan svjesnim uvođenjem statičke nelinearnosti u regulacijski blok kao što je to ovdje slučaj, a koji zajedno sa linearnim objektom regulacije tvori Hamerštajnov model [76]. Statičke nelinearne karakteristike snimljene pri različitim vrijednostima slobodnih F i β parametara pri ulaznoj nagibnoj funkciji dani su dijagramima na (slika 2.12). Pritom snimljena nelinearna neizrazita pojačanja (5.7) su dana dijagramima na slici 2.13. Kao osnovni zadatak neizrazitom analitičkom regulatoru osim željenog gibanja upravljačke trajektorije prilikom vođenja mobilnog robota referentnom trajektorijom, postavlja se i eliminiranje mogućih vanjskih poremećaja. Vanjske poremećaje svedene na stranu regulatora Δu_p možemo podijeliti na poremećaje slučajne nemjerljive (stohastičke) prirode Δu_{ps} i poremećaje koji se mogu izmjeriti uvođenjem dodatne mjerne opreme Δu_{pm} . Uz poremećaje stohastičke prirode postoje i fiktivni poremećaji Δu_{pf} koji predstavljaju ekvivalent onoga što se u trenutku formiranja matematičkog modela objekta regulacije (procesa) o sustavu ne zna, te se dijelom ili u potpunosti mogu opisati statistički. S tog stajališta odstupanje prve derivacije vektora stanja dano izrazom (4.34) poprima proširenu formu

$$\Delta \mathbf{X}(n+1) = \mathbf{A}_d \Delta \mathbf{X}(n) + \mathbf{B}_d [\Delta \mathbf{U}_r(n) + \Delta \mathbf{U}_{pm}(n) + \Delta \mathbf{U}_{ps}(n) + \Delta \mathbf{U}_{pf}(n)] , \quad (5.8)$$

Ako iz dinamičkog modela odstupanja stanja od željenog (5.8), postignutog postupkom adaptiranja slobodnih parametara neizrazitog regulatora (poglavlje 4), isključimo sve vanjske poremećaje $\Delta u_{pm} = \Delta u_{ps} = \Delta u_{pf} = 0$ i ograničimo se prvenstveno na poremećaje tipa početnih uvjeta dolazi se do autonomnog dinamičkog sustava prikazanog na (slici 5.1).



Slika 5.1 Struktura dinamičkog modela odstupanja od željene referentne trajektorije sa implementiranim **NAR** pri djelovanju početnog poremećaja..


Promjena neizrazite upravljačke varijable $\Delta u_r = u - u_n$ podliježe amplitudnim ograničenjima statičke nelinearnosti. Ako sa $(\Delta u_r)_{\max} = u_{\max} - u_n$ označimo maksimalno moguće odstupanje napona (u) od nominalnog (željenog) (u_n) onda pri statičkoj nelinearnosti vrijede slijedeća ograničenja

$$Ne(\Delta u_r) = \begin{cases} \Delta u_r & \text{za } |\Delta u_r| < (\Delta u_r)_{\max} , \\ \text{sgn}(\Delta u_r)(\Delta u_r)_{\max} & \text{za } |\Delta u_r| \geq (\Delta u_r)_{\max} , \end{cases} \quad (5.9)$$

koja su prikazana i grafički na slici 5.2a. U prethodnom izrazu sa $Ne(\Delta u_r)$ označena je nelinearna funkcija prirasta upravljačke varijable Δu_r . Ako se maksimalni prirast amplitude neizrazite upravljačke varijable ograniči na $|(\Delta u_r)_{\max}| = 15V$, onda pri točno određenim vrijednostima stanja pogreške pozicije i brzine koje čine uređeni par $(e, \Delta e)$ dolazi se do graničnih nivo upravljačkih krivulja

$$\Psi_{\max}(e, \Delta e) = +(\Delta u_r)_{\max} = +15V , \text{ odnosno } \Psi_{\min}(e, \Delta e) = -(\Delta u_r)_{\max} = -15V , \quad (5.10)$$

koje su prikazane u faznoj ravlini stanja pogreške pozicije i brzine na (slici 5.2b).



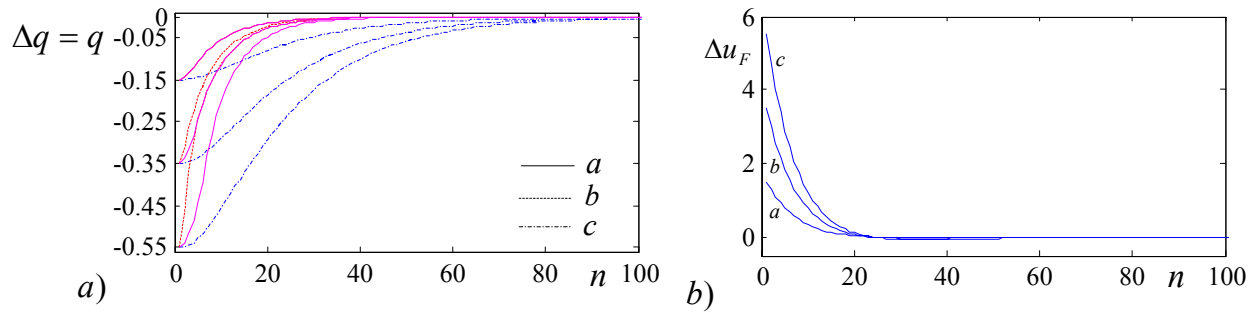
Slika 5.2 Grafički prikaz statičke nelinearnosti tipa Amplitudnog Zasićenja (AZ) a), prikazanih faznom ravninom stanja pogreške pozicije i brzine pri nelinearnim funkcijama ograničenja $\pm \Psi_{\max}(e, \Delta e) = |(\Delta u_r)_{\max}|$ na upravljačku varijablu u_r b).

Granične nivo upravljačke krivulje omeđuju osjenčani dio fazne ravnine uređenih parova $(e, \Delta e)$ koje podliježu normalnom progresivnom režimu rada nelinearnog neizrazitog regulatora. S gornje i donje strane graničnih upravljačkih krivulja, prikazano šrafiranim dijelom u faznoj ravlini stanja (slika 5.2b) je područje zasićenja upravljačke varijable. Pri tome ne vrijede ograničenja prirasta neizrazite upravljačke varijable

$$\Psi_{\min}(e, \Delta e) \leq \Psi(e, \Delta e, n) \leq \Psi_{\max}(e, \Delta e) , \quad (5.11)$$

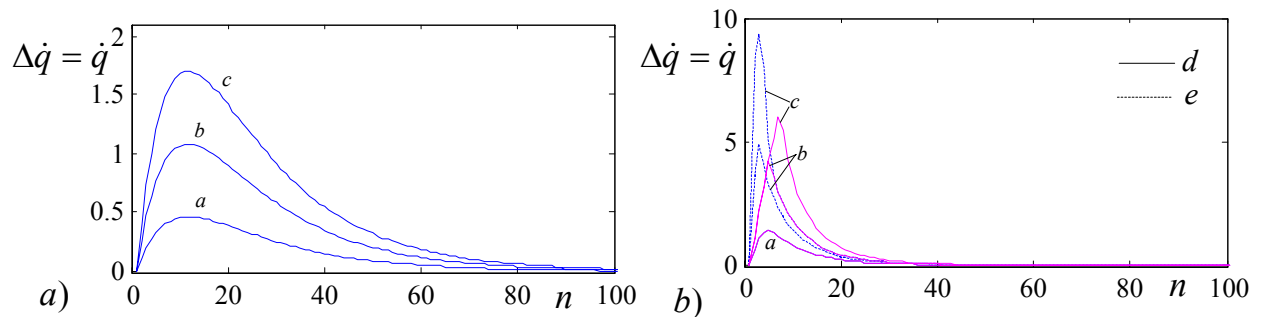
odnosno zatvaranjem regulacijskih petlji pozicije i brzine zahtijeva se pri stanjima pogreške pozicije i brzine $(e, \Delta e)$ u šrafiranom dijelu fazne ravnine stanja veći prirast upravljačke varijable nego što se to u realnim uvjetima određenim izrazom (5.11) može ostvariti. **PD-PNAR** dan na

slici 5.1 u službi je otklanjanja vanjskih poremećaja tipa početnih uvjeta koji ne moraju biti definirani uvijek u početnom trenutku vremena ($t=0$) nego se isti mogu javiti u bilo kojem trenutku praćenja nominalne referentne trajektorije. Ako se prvenstveno ograničimo na različite poremećaje tipa početnih uvjeta definiranih vremenskim trenutkom ($t=0$), onda dolazimo do ostvarenih trajektorija pozicije prikazanih slikom 5.3a.



Slika 5.3 a) Ostvarene trajektorije u prostoru unutarnjih koordinata sa linearnim **PD**-regulatorom (-c), nelinearnim **PD-PNAR**-om sa (-a) i bez statičke nelinearnosti (-b) tipa **AZ** (Slika 5.2); b) Prikaz promjene upravljačke varijable sa implementiranim linearnim PD-regulatorom pri različitim vrijednostima poremećaja tipa početnih uvjeta $\Delta q = -0,15$ (-a), $\Delta q = -0,35$ (-b) i $\Delta q = -0,55$ (-c).

Kako su pogreške pozicije definirane kao odstupanje pozicije od nominalne vrijednosti, onda pri nultoj nominalnoj vrijednosti dinamičkog sustava (slika 5.1) trajektorije pozicije i brzine su ujedno i trajektorije pogreške pozicije (slika 5.3.a) i brzine (slika 5.4).

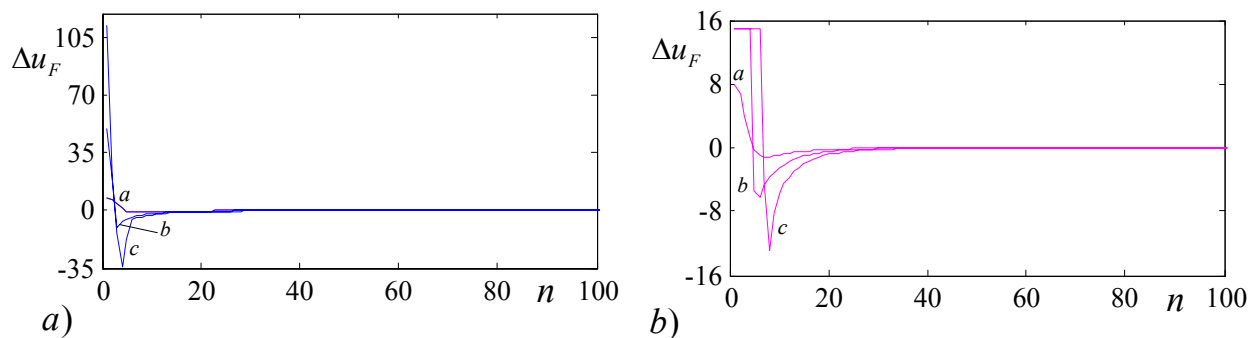


Slika 5.4 Ostvarene trajektorije brzine u prostoru unutarnjih upravljanih koordinata sustava sa linearnim **PD**-regulatorom a) i nelinearnim **PD-PNAR**-om b), sa (-d) i bez statičke nelinearnosti (-e), **AZ** (slika 5.2) pri različitim vrijednostima početnih uvjeta (slika 5.3)

Kod autonomnog sustava sa implementiranim **PD-PNAR**-om parametara:

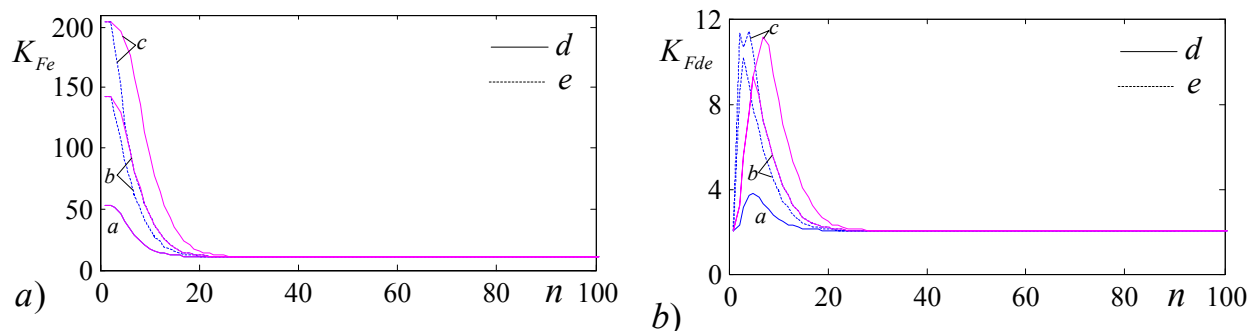
$$F_e = 13,333; \beta_e = 0,0012; F_{de} = 6,667; \beta_{de} = 0,0048; |e|_{max} = 1; |de|_{max} = 10 \quad U_m = 15 \quad 5.12$$

brzina odziva odnosno brzina prijelaznog procesa ($-b$) je veća za razliku od sustava sa implementiranim linearnim **PD**-regulatorom ($-c$) pojačanja pozicije $K_P=10$ i brzine $K_V=2$. Pritom promjene upravljačke varijable za različite vrijednosti poremećaja početnih uvjeta (slika 5.3.b) podliježu zakonitosti (5.11) odnosno pogreške pozicije ($-c$) na (slici 5.3a) i brzine (slika 5.4a) nalaze se unutar osjenčanog područja fazne ravnine stanja (slika 5.2b). Pri većim vrijednostima poremećaja $\Delta q=-0,35$ i $\Delta q=-0,55$ kod sustava sa implementiranim neizrazitim regulatorom upravljačka varijabla podliježe amplitudnom ograničenju statičke nelinearnosti navedene izrazom (5.9) što osim smanjenja pogreške po brzini ($-d$) (slika 5.4b), ima za posljedicu i smanjenje brzine odziva odnosno vremena uspona ($-a$) kao što je to prikazano na (slici 5.3a).



Slika 5.5 Promjena neizrazite upravljačke varijable dinamičkog sustava (slika 5.1) sa implementiranim nelinearnim **PD-PNAR**-om sa b) i bez statičke nelinearnosti a), **AZ** upravljačke varijable (slika 5.2) pri različitim vrijednostima početnih uvjeta (slika 5.3)


Kod većih vrijednosti poremećaja neizrazita upravljačka varijabla Δu_F poprima vrlo velike vrijednosti (slika 5.5a) koje se nakon primjene važećih ograničenja (5.9) svode u okvire realnih ostvarivih mogućnosti (slika 5.5b). Sa čisto formalnog matematičkog stajališta danim izrazima (5.7) na slici 5.6a i 5.6b grafički su prikazane vrijednosti neizrazitih pojačanja pozicije i brzine pri različitim vrijednostima početnih poremećaja.



Slika 5.6 Vrijednosti neizrazitih pojačanja pozicije K_{Fe} a) i brzine K_{Fde} b), sa ($-d$) i bez statičke nelinearnosti ($-e$), **AZ** upravljačke varijable (slika 5.2), pri različitim vrijednostima

poremećaja tipa početnih uvjeta $\Delta q = -0,15$ (a), $\Delta q = -0,35$ (b) i $\Delta q = -0,55$ (c) (slika 5.3)

Djelovanje neizrazitog regulatora u ovom slučaju se ogleda u tome što većim poremećajima od željene trajektorije odgovaraju i veće vrijednosti pojačanja a s tim i veći stupanj asimptotske stabilnosti pa otuda proizlaze i veće brzine odziva u smislu asimptotskog iščezavanja pogreške odnosno njezinog približavanja nominalnoj nultoj vrijednosti. Pri nultim poremećajima, pojačanja neizrazitog regulatora jednaka su pojačanjima linearnog **PD**-regulatora, pri čemu je to ujedno i granični slučaj djelovanja neizrazitog analitičkog regulatora (slika 5.6). Pri djelovanju statičke nelinearnosti tipa amplitudnog zasićenja neizrazite upravljačke varijable, pri pogreškama pozicije i brzine izvan osjenčanog područja fazne ravnine stanja (slika 5.2) dolazi do porasta neizrazitog pojačanja pozicije odnosno pada neizrazitog pojačanja brzine, što dovodi redom do udaljavanja odnosno približavanja polova imaginarnoj osi S-ravnine. Kod proizvoljno odabranih slobodnih parametara neizrazitog analitičkog regulatora (5.12), pri većim iznosima poremećaja moguće su nestabilnosti koje dovode do raspirenih oscilacija (slika 5.7b) odnosno do granične stabilnosti pri nešto manjim vrijednostima (slika 5.7a).



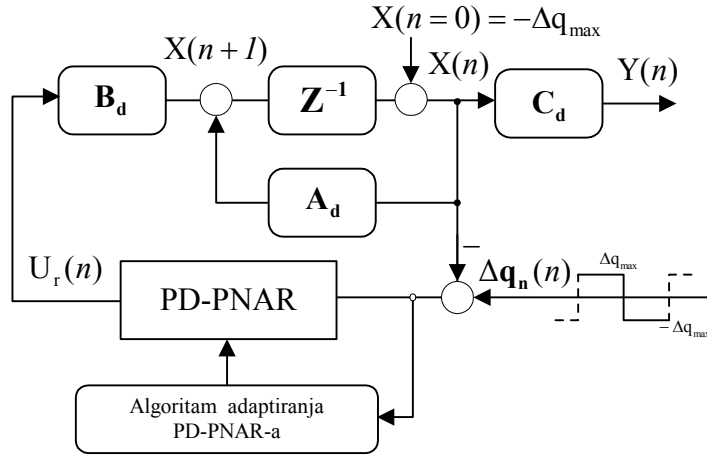
Slika 5.7 Grafički prikazi granične stabilnosti a) i nestabilnosti b) pri odabranim većim vrijednostima poremećaja tipa početnih uvjeta.

5.2 Adaptiranje PD-PNAR-a

U prethodnom podpoglavlju pokazano je da je kod neizrazitog analitičkog regulatora proizvoljno odabranih parametara (5.12), brzina iščezavanja poremećaja različita pri različitim vrijednostima poremećaja tipa početnih uvjeta. Pri projektiranju neizrazitog analitičkog regulatora u svrhu otklanjanja vanjskih poremećaja potrebno je odrediti njegove slobodne parametre na osnovu poznate procijenjene vrijednosti maksimalne pogreške. Prije procesa adaptiranja potrebno je stoga poznavati raspon vrijednosti pogreški, kako prilikom realne primjene ne bi došlo do moguće nestabilnosti (slika 5.7). Početnim podešavanjem **PD-PNAR**-a dobiveni su parametri

$$F_e=0,48 \quad \beta_e=0,033 \quad F_{de}=1,176 \quad \beta_{de}=0,0272 \quad |e|_{\max}=1 \quad |de|_{\max}=10 \quad U_m=15 \text{ V} \quad (5.13)$$

koji odgovaraju parametrima familija karakterističnih krivulja $K_{np}=10$ i $K_{nv}=2$.



Slika 5.8 Struktura adaptiranja slobodnih parametara **PD-PNAR**-a pri procijenjenoj maksimalnoj vrijednosti vanjskog poremećaja tipa početnih uvjeta Δq_{\max} .

U nastavku će biti izložen postupak adaptiranja slobodnih parametara **PD-PNAR**-a, s obzirom na moguće vanjske poremećaje kao što su poremećaji tipa početnih uvjeta. Zbog toga se kao ulazna veličina dinamičkog sustava mobilnog robota, uzima pravokutni izmjenični signal amplitude koja odgovara polovini procijenjene maksimalne vrijednosti poremećaja oko nominalne željene vrijednosti (slika 5.8). Kao referenca uzima se jedna kompletna promjena poremećaja u pozitivnom i negativnom smjeru u trajanju 2s i koja se tokom vremena ponavlja, dok se ne postigne minimalna vrijednost integralnog kriterija danog izrazom (4.18). Iako se općenito od algoritma adaptacije zahtjeva što veći broj koraka pogreške, ovdje se predlaže algoritam adaptacije koji u svakom koraku sadrži pogrešku pozicije i brzine. Slobodne parametre u slijedećem normaliziranom vremenski diskretnom koraku dobivamo izrazima što slijede

$$\begin{aligned} F_e(n+1) &= F_e(n) + (\hat{\delta}_{Fe1}e(n) + \hat{\delta}_{Fe2}e(n-1))\Theta_{Fe}(n) , \\ \beta_e(n+1) &= \beta_e(n) + (\hat{\delta}_{\beta e1}\beta_e^2(n)e(n) + \hat{\delta}_{\beta e2}\beta_e^2(n)e(n-1))\Theta_{Fe}(n) , \\ F_{de}(n+1) &= F_{de}(n) + (\hat{\delta}_{Fde1}e(n) + \hat{\delta}_{Fde2}e(n-1))\Theta_{Fde}(n) , \\ \beta_{de}(n+1) &= \beta_{de}(n) + (\hat{\delta}_{\beta de1}\beta_{de}^2(n)e(n) + \hat{\delta}_{\beta de2}\beta_{de}^2(n)e(n-1))\Theta_{Fde}(n) , \end{aligned} \quad (5.14)$$

gdje se promjenjivi koeficijenti učenja $\hat{\delta}_{Fe1}$ i $\hat{\delta}_{Fe2}$ po iteracijama definiraju kao

$$\hat{\delta}_{Fe1} = \delta_{Fe1} e^{\sigma_1 \frac{ISE_1 - ISE}{ISE_1}} , \quad \hat{\delta}_{Fe2} = \delta_{Fe2} e^{\sigma_2 \frac{ISE_2 - ISE}{ISE_2}} . \quad (5.15)$$

sa integralnim kriterijem kvadrata pogreške na početku procesa adaptacije međusobno približno jednakim $ISE_1 \cong ISE_2 = 0,055$, i pozitivno semidefinitnim konstantama $\sigma_F = 2$ i $\sigma_2 = 0,5$. Ostali koeficijenti učenja u svrhu očuvanja stabilnosti predloženog algoritma adaptiranja (5.14) biraju se tako da približno budu zadovoljeni njihovi međusobni odnosi

$$\frac{\hat{\delta}_{\beta e1}}{\hat{\delta}_{Fe1}} \cong \frac{\hat{\delta}_{\beta e2}}{\hat{\delta}_{Fe2}} = \delta_1, \quad \frac{\hat{\delta}_{\beta de1}}{\hat{\delta}_{Fe1}} \cong \frac{\hat{\delta}_{\beta de2}}{\hat{\delta}_{Fe2}} = \delta_2, \quad \frac{\hat{\delta}_{Fde1}}{\hat{\delta}_{Fe1}} \cong \frac{\hat{\delta}_{Fde2}}{\hat{\delta}_{Fe2}} = \delta_3, \quad (5.16)$$


gdje su pritom δ_{Fe1} , δ_{Fe2} , $\delta_{\beta e1}$, $\delta_{\beta e2}$, δ_{Fde1} , δ_{Fde2} , $\delta_{\beta de1}$, $\delta_{\beta de2}$ pozitivne konstante koje određuju brzinu učenja i dane su tablicom 5.1.

parametri	e	de
δ_{F1}	1,6	-0,21
δ_{F2}	-0,8	0,1
$\delta_{\beta 1}$	-3,34	0,88
$\delta_{\beta 2}$	1,67	-0,42

Tablica 5.1 Koeficijenti brzine učenja nelinearnog algoritma adaptiranja početno ugođenog **PD-PNAR-a**

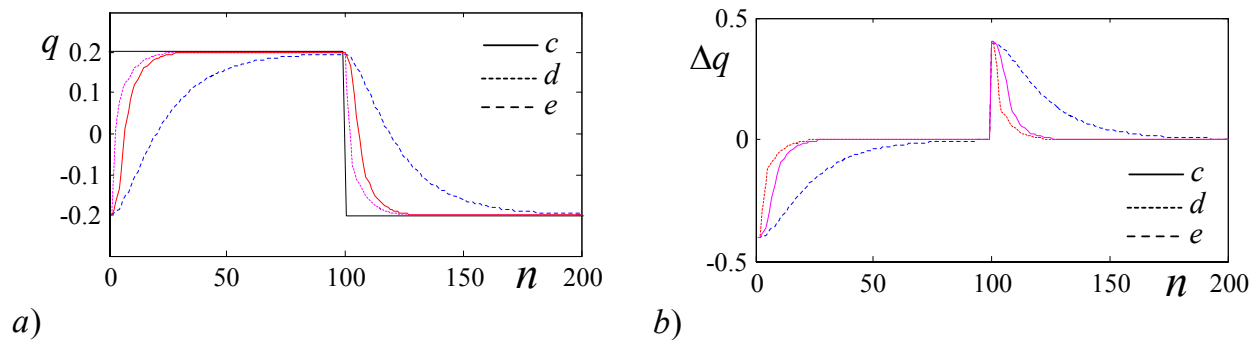
Varijable Θ_{Fe} i Θ_{Fde} u predloženom algoritmu adaptiranja (5.14) su promjenjive po normaliziranim vremenski diskretnim koracima i predstavljaju osjetljivosti neizrazitih upravljačkih varijabli o slobodnim parametrima definiranim izrazom (2.71) odnosno (2.73). Nakon završene 97 iteracije predloženim algoritmom (5.14) postignuti integralni kriterij kvadratne pogreške je $ISE=0,01$ (slika 5.9) a pritom postignuti slobodni parametri neizrazitog analitičkog regulatora su

$$F_e = 29,46 \quad \beta_e = 54,23 \cdot 10^{-5} \quad F_{de} = 8,34 \quad \beta_{de} = 382,93 \cdot 10^{-5} \quad (5.17)$$



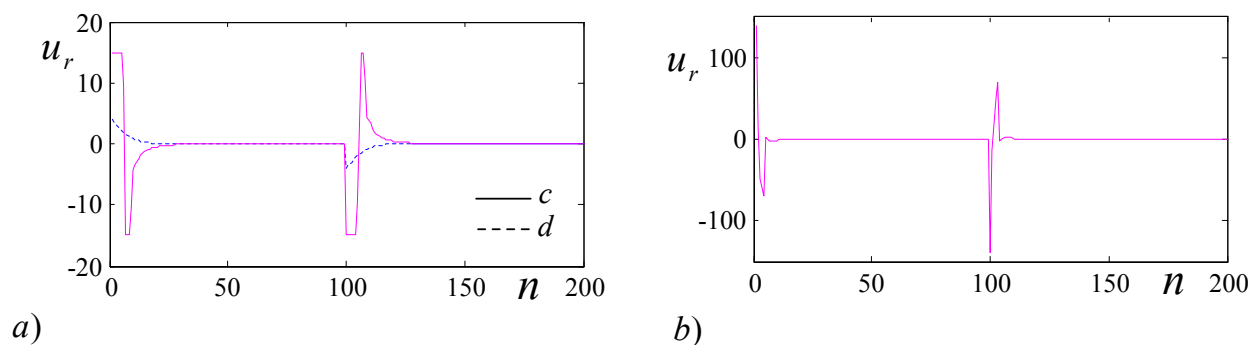
Slika 5.9 Grafički prikaz vrijednosti ISE pozicije (4.18) po iteracijama (promjenama reference) pri procesu adaptiranja slobodnih parametara **PD-PNAR-a**.

Po završetku postupka adaptiranja na dijagramima (slika 5.10a), vidljivo je značajno povećanje brzine prijelaznog procesa u odnosu na početno stanje (-c), što u slučaju poremećaja tipa početnih uvjeta na referentnoj trajektoriji gibanja mobilnog robota govori o povećanom stupnju asimptotske stabilnosti odnosno bržem iščezavanju poremećaja (-b), (slika 5.10b).



Slika 5.10 Grafički prikaz ostvarene trajektorije poremećaja a) i pogreške b) na početku (-e) i na završetku adaptiranja nakon 97 promjena reference sa (-c) i bez (-d) statičke nelinearnosti **AZ** neizrazite upravljačke varijable **PD-PNAR-a**.

Zbog povećane brzine prijelaznog procesa upravljačka varijabla poprima značajnije vrijednosti (slika 5.11b) koje su zbog ograničenih resursa upravljačke varijable i naponskog pojačala snage limitirane (slika 5.11a), što ima za direktnu posljedicu smanjenje brzine prijelaznog procesa.



Slika 5.11 Grafički prikaz neizrazite upravljačke varijable na početku (-d) i na završetku adaptiranja nakon 97 iteracija (-c), sa a) i bez b) statičke nelinearnosti **AZ** upravljačke varijable.

5.3 Stabilnost predloženog algoritma adaptiranja PD-PNAR-a

Izrazima (5.16) dani su nužni uvjeti stabilnosti algoritma samoorganiziranja. Da bi odredili dovoljne uvjete stabilnosti ovdje se polazi od općeg energetskog pristupa klasične mehanike koja govori da se ukupna energija nekonzervativnog mehaničkog sustava smanjuje tokom vremena. Procjena sa potrebnim uvjetima stabilnosti algoritma adaptiranja određuju se direktnom ili drugom Lyapunovom metodom [58,59,77,87] pri čemu je potrebno definirati energetska skalarnu funkciju $V(x_1, x_2, \dots, x_n)_{(n)}$ varijabli stanja koja je analogna, pohranjenoj energiji u sustavu. Kako se ovdje razmatraju mogući vanjski poremećaji oko ravnotežnog stanja definiranog željenom dinamikom (4.38) sustav će biti asimptotski stabilan uz pozitivno (negativno) definitnu skalarnu funkciju V , koju je potrebno prema teoremi Lyapunova tako odabrati da njezina prva derivacija \dot{V} bude negativno (pozitivno) definitna. Za odabranu skalarnu funkciju V u okolini R ravnotežne trajektorije kretanja sustava (slika 4.31) za koju vrijedi da je odstupanje (poremećaj) $\|\Delta x\|$ manji od unaprijed zadane procijenjene vrijednosti $\Delta q_{max} > 0$ kaže se da je pozitivno definitna ako ispunjava slijedeće uvijete [77]:

- 1) Zadržava isti predznak u okolini R , odnosno da vrijedi $R: V(\Delta x) > 0, \Delta x \neq 0$,
- 2) Pri izostalom poremećaju vrijednost skalarne funkcije V je nula tj. $V(\Delta x) = 0$ za $\Delta x = 0$, (5.18)
- 3) Postoje kontinuirane parcijalne derivacije po odstupanju $\dot{V} = \partial V / \partial \Delta x$,

dok se negativna definitnost određuje inverzijom predznaka u okolini R nominalne trajektorije.

Usvajanjem odnosa danih izrazima (5.16), priraste slobodnih parametara dane rekursivnim formulama (5.14) zapisujemo u nešto sažetijem obliku

$$\begin{aligned} \Delta F_e(n) &= (\hat{\delta}_{Fe1} e(n) + \hat{\delta}_{Fe2} e(n-1)) \Theta_{Fe}(n) , \\ \Delta \beta_e(n) &= \delta_1 \beta_e^2(n) \Delta F_e(n) , \\ \Delta F_{de}(n) &= \delta_3 (\hat{\delta}_{Fe1} e(n) + \hat{\delta}_{Fe2} e(n-1)) \Theta_{Fe}(n) , \\ \Delta \beta_{de}(n) &= \delta_2 / \delta_3 \beta_{de}^2(n) \Delta F_{de}(n) . \end{aligned} \quad (5.19)$$

Prirast upravljačke varijable $(\Delta u_r)_i$ servosustava na nivou i -tog stupnja slobode gibanja je uvjetovan prirastom neizrazite upravljačke varijable $(\Delta u_F)_i$ **PD-PNAR**-a (slika 5.8), uslijed promjene slobodnih parametara predloženim algoritmom adaptiranja (5.19). Na osnovu izraza (4.8) dobiva se

$$(\Delta u_r)_i = (\Delta u_F)_i = \left[\Theta_{Fe} + \Theta_{\beta_e} \delta_1 \beta_e^2 \right]_{(n)} \Delta F_e(n) + \left[\Theta_{F_{de}} + \Theta_{\beta_{de}} \delta_2 / \delta_3 \beta_{de}^2 \right]_{(n)} \Delta F_{de}(n) . \quad (5.20)$$

Kako u diskretnom području vrijedi da je $e_i(n-1)=-\Delta q_i(n-1)=\Delta x_i(n)$ i $e_i(n)=-\Delta q_i(n)=\Delta x_{n+i}(n)$, onda je prirast vektora stanja $\Delta \mathbf{X}_i(n)$ na nivou i -tog stupnja slobode prema izrazima (4.47) jednak

$$\Delta \mathbf{X}_i(n) = [\Delta x_i(n) \quad \Delta x_{n+i}(n)]^T = [\Delta q_i(n-1) \quad \Delta q_i(n)]^T . \quad (5.21)$$

Uz ovaj izraz i izraze (5.18) prirast neizrazite upravljačke varijable (5.19) je u matričnom obliku

$$(\Delta u_r)_i = \mathbf{\Omega}_i^T(n) \Delta \mathbf{X}_i(n) , \quad (5.22)$$

gdje su komponente redne matrice $\mathbf{\Omega}_i^T(n) = [\Omega_{i1} \quad \Omega_{i2}]$ varijabilne po normaliziranim vremenski diskretnim koracima i dobivaju se izrazima

$$\begin{aligned} \Omega_{i1}(n) &= -\hat{\delta}_{Fe1} \left(\Theta_{Fe}^2 + \Theta_{Fe} \Theta_{\beta_e} \delta_1 \beta_e^2 + \Theta_{Fde}^2 \delta_3 + \Theta_{Fde} \Theta_{\beta_{de}} \delta_2 \beta_{de}^2 \right) , \\ \Omega_{i2}(n) &= -\hat{\delta}_{Fe2} \left(\Theta_{Fe}^2 + \Theta_{Fe} \Theta_{\beta_e} \delta_1 \beta_e^2 + \Theta_{Fde}^2 \delta_3 + \Theta_{Fde} \Theta_{\beta_{de}} \delta_2 \beta_{de}^2 \right) . \end{aligned} \quad (5.23)$$

Iako se sa stajališta predloženog nelinearnog algoritma adaptacije (5.14), radi o inherentno nelinearnom, vremenski varijabilnom autonomnom sustavu (4.50) moguće je polazeći od modela odstupanja ili signala razlike

$$\Delta \dot{\mathbf{X}} = \mathbf{A} \Delta \mathbf{X} , \quad \Delta \mathbf{X}(t=0) = \Delta \mathbf{X}_{0i} , \quad (5.24)$$

uz pomoć elektroničkog računala procijeniti dovoljne uvijete stabilnosti algoritma samoorganiziranja služeći se tehnikama kontinuiranih linearnih vremenski invarijantnih sustava. U tu svrhu koristimo se energetsom metodom gdje funkciju Lyapunova uzimamo u obliku simetrične kvadratne forme

$$V(\Delta \mathbf{X}) = \Delta \mathbf{X}^T \mathbf{G} \Delta \mathbf{X} , \quad (5.25)$$

gdje je \mathbf{G} općenito pozitivno definitna simetrična matrica sa elementima

$$\mathbf{G} = \begin{bmatrix} g_{11} & g_{12} \\ g_{21} & g_{22} \end{bmatrix} . \quad (5.26)$$

Nakon uvrštavanja (5.24) u derivaciju matrične jednadžbe (5.25), za prvu derivaciju skalarne funkcije V dobiva se

$$\dot{V}(\Delta \mathbf{X}) = \Delta \mathbf{X}^T \mathbf{G}_1 \Delta \mathbf{X} . \quad (5.27)$$

U slučaju asimptotski stabilnog sustava prema Lyapunovu simetrična matrica \mathbf{G}_1 treba biti negativno definitna

$$\mathbf{G}_1 = \mathbf{A}^T \mathbf{G} + \mathbf{G} \mathbf{A} . \quad (5.28)$$

Kako je na osnovu izraza (4.48 i 5.23) matrica \mathbf{A} zadana u vremenski diskretnom području matricom koeficijenata sustava $\hat{\mathbf{A}}_{di} = \mathbf{A}_{di} + \mathbf{B}_{di} \mathbf{\Omega}$, moguće je zamjenom matrica \mathbf{A} i \mathbf{G}_1 prethodnog izraza matričnim jednadžbama:

$$\mathbf{A} = (\hat{\mathbf{A}}_{di} - \mathbf{I})(\hat{\mathbf{A}}_{di} + \mathbf{I})^{-1}, \quad \mathbf{G}_1 = 2(\hat{\mathbf{A}}_{di} + \mathbf{I})^{-T} \mathbf{G}_{d1} (\hat{\mathbf{A}}_{di} + \mathbf{I})^{-1}, \quad (5.29)$$

doći do diskretnog oblika Ljapunove matrične jednadžbe

$$\mathbf{G}_{d1} = \hat{\mathbf{A}}_{di}^T \mathbf{G} \hat{\mathbf{A}}_{di} - \mathbf{G}. \quad (5.30)$$

Ako sa stajališta diskretne tehnike treći uvjet (5.18) uz zadržavanje preostala dva preuredimo tako da prirast Lyapunove skalarne funkcije $\Delta V(n)$ po normaliziranim vremenski diskretnim koracima (n) poprima konačne ograničene vrijednosti, onda se na osnovu izraza (4.50 i 5.27) matričnom jednadžbom

$$\Delta V = V(\Delta X, n+1) - V(\Delta X, n) = \Delta \mathbf{X}^T(n) \mathbf{G}_{d1} \Delta \mathbf{X}(n), \quad (5.31)$$

također se dolazi do simetrične negativno definitne diskretne matrice \mathbf{G}_{d1} (5.30). Prikladnim odabiranjem njezinih komponenti i važećeg izraza (5.29) Lyapunov zadatak u diskretnom području (5.30), [58,59,87] može se svesti na izračunavanje matrice \mathbf{G} korištenjem Lyapunove matrične jednadžbe vremenski kontinuiranih sustava (5.28). Za pozitivno definitnu simetričnu matricu \mathbf{G} , prema Sylvesterovu teoremu treba da vrijedi

$$g_{11} > 0, \quad g_{11}g_{22} - g_{12}^2 > 0. \quad (5.32)$$

Iz prethodnih uvjeta slijede nejednadžbe

$$\Omega_{11}(n) < 0, \quad \frac{KQ}{KR} + \frac{\Omega_{11}T_s}{2} - \frac{2}{KR} < \Omega_{12}(n) < \frac{KQ}{KR} + \Omega_{11}T_s, \quad (5.33)$$

koje predstavljaju dovoljne uvjete stabilnosti, ekvivalentne onima dobivenim Juryjevim testom stabilnosti (4.55-56), koji ovdje uz izraze (5.23) se davaju u konačnom obliku

$$\Omega_{11} = \hat{\delta}_{Fe1} \nu_1 < 0, \quad \frac{KQ}{KR} + \frac{\Omega_{11}T_s}{2} - \frac{2}{KR} < \hat{\delta}_{Fe2} \nu_1 < \frac{KQ}{KR} + \Omega_{11}T_s, \quad (5.34)$$

gdje je vremenski varijabilna vrijednost $\nu_1(n)$ određena sa

$$\nu_1(n) = \Theta_{Fe}^2 + \Theta_{Fe} \Theta_{\beta_e} \delta_1 \beta_e^2 + \Theta_{Fde}^2 \delta_3 + \Theta_{Fde} \Theta_{\beta_{de}} \delta_2 \beta_{de}^2. \quad (5.35)$$

Prethodno navedeni izrazi (5.33-35) govore da u svakom trenutku vremena, vremenski promjenjive komponente Ω_{11} i Ω_{12} redne matrice $\mathbf{\Omega}^T(n)$ trebaju zadovoljavati postavljena ograničenja. Kako nejednadžbe (5.34-35) imaju pet nepoznanica na koje možemo utjecati onda koeficijent učenja $\hat{\delta}_{Fe1}$ s odnosima δ_1 i δ_2 biramo proizvoljno, dok brzinu učenja δ_{Fe2} i odnos δ_3 uz važeće izraze (5.15) određujemo iz nejednadžbi, tako da prilikom očuvanja asimptotske stabilnosti algoritma adaptiranja općenito treba da vrijedi:

$$\delta_3 < \left\{ - \left(\Theta_{Fe}^2 + \Theta_{Fe} \Theta_{\beta_e} \delta_1 \beta_e^2 + \Theta_{Fde} \Theta_{\beta_{de}} \delta_2 \beta_{de}^2 \right) / \Theta_{Fde}^2 \right\}_{\min}, \quad (5.36)$$

$$\left\{ \nu - \frac{2}{\nu_1(\delta_3)KR T_s} \right\}_{\max} < \delta_{Fe2} < \left\{ \nu + \frac{\delta_{Fe1} T_s}{2} \right\}_{\min} . \quad (5.37)$$

u kojoj ν označava vremenski varijabilnu granicu intervala stabilnosti faktora brzine učenja δ_{Fe2}

$$\nu = \frac{KQ}{KR \nu_1(\delta_3)} + \frac{\delta_{Fe1} T_s}{2} . \quad (5.38)$$

Dakle potrebno je procijeniti minimalne odnosno maksimalne vrijednosti iznosa danih izrazima unutar vitičastih zagrada (5.36 i 5.37). To je moguće napraviti uz pomoć simulacije na elektroničkom računalu. Pokazalo se je da je osjetljivost neizrazite upravljačke varijable o F parametru najveća, a o β parametru najmanja na početku procesa adaptacije. Kako u prvoj iteraciji približno vrijedi $ISE \cong ISE_1 \cong ISE_2$, onda eksponencijalni član izraza (5.15) postaje jednak jedinici i izostavlja se iz nejednadžbi (5.34-35), što ima za posljedicu da su koeficijenti učenja približno jednaki brzinama učenja $\hat{\delta}_{Fe1} \cong \delta_{Fe1}$ i $\hat{\delta}_{Fe2} \cong \delta_{Fe2}$. Kako osjetljivost upravljačke varijable o F parametru ulazi sa kvadratom svoje vrijednosti, dominantni je pribrojnik u nejednadžbama (5.35-36), onda procjenu maksimalne odnosno minimalne vrijednosti izraza danih unutar vitičastih zagrada (5.36 i 5.37) pri određivanju odnosa δ_3 i brzine učenja δ_{Fe2} najbolje je vršiti u zadnjoj odnosno prvoj iteraciji postupka adaptiranja.

5.4 Uvjeti stabilnosti algoritma regulacije

Ako ovdje analizu pojednostavimo do te mjere da odmah na početku na nivou i-tog stupnja slobode gibanja, odnosno za regulator drugog reda danog izrazima u obliku

$$\Delta \dot{x}_1 = \Delta x_2(t) , \quad \Delta \dot{x}_2 = -KQ \Delta x_1 + KR \Delta u_r , \quad \Delta u_r = \Psi(\Delta x_1, \Delta x_2, t) , \quad (5.39)$$

definiramo pozitivno definitnu simetričnu matricu \mathbf{G} kao jediničnu $\dim(2 \times 2)$, pritom ne gubeći na općem značaju, iz izraza (5.27) dobiva se pozitivno definitna funkcija Lyapunova u obliku

$$V(\Delta x_1, \Delta x_2) = \frac{1}{2} (\Delta x_1^2 + \Delta x_2^2) , \quad (5.40)$$

a njezina prva derivacija se definira kao

$$\dot{V}(\Delta x_1, \Delta x_2) = \Delta x_1 \Delta \dot{x}_1 + \Delta x_2 \Delta \dot{x}_2 . \quad (5.41)$$

Uvrštavanjem izraza (5.39) u prethodni dobiva se

$$\dot{V}(\Delta x_1, \Delta x_2) = \Delta x_2 \left[\frac{\Delta x_1}{KR} - \frac{KQ}{KR} \Delta x_1 + \Psi(\Delta x_1, \Delta x_2, t) \right] . \quad (5.42)$$

Kako vrijedi da je $KR > 0$ i $KQ > 0$, onda se negativna definitnost prve derivacije funkcije Lyapunova ogleda kroz slijedeća ograničenja:

$$\Psi(\Delta x_1, \Delta x_2, t) > \frac{KQ}{KR} \Delta x_1 - \frac{\Delta x_1}{KR}, \quad \text{za } \Delta x_2 < 0, \quad (5.43)$$

$$\Psi(\Delta x_1, \Delta x_2, t) < \frac{KQ}{KR} \Delta x_1 - \frac{\Delta x_1}{KR}, \quad \text{za } \Delta x_2 > 0. \quad (5.44)$$

Kako bi se očuvala asimptotska stabilnost za različite vrijednosti pogreške pozicije i brzine, moguće je na temelju prethodno navedenih ograničenja odrediti granice podprostora mogućih djelovanja neizrazite upravljačke varijable. Kako je analitički regulator nelinearne varijabilne strukture, provjerom prethodnih ograničenja u bilo kojem trenutku vremena dobiva se informacija o stabilnosti sustava ali ne informacija i o dinamici promjene slobodnih parametara regulatora koji direktno utječu na promjenu položaja neizrazite upravljačke površine. Zato je u poglavlju 4 i potpoglavlju 5.2 detaljno izložen algoritam procesa adaptacije parametara neizrazitog analitičkog regulatora u analitičkom obliku koji osigurava takvu dinamiku hiper ravnine $\Psi(\Delta x_1, \Delta x_2, t)$ podprostora djelovanja neizrazite upravljačke varijable $u_r = u_F$ da u svakom trenutku vremena budu ispoštovana ograničenja dana nejednadžbama (5.44).

5.5 Nelinearni PI i PID-PNAR i konstantni nemjerljivi poremećaji

(podešavanje integralnog pojačanja)

Osim poremećaja tipa početnih uvjeta duž referentne trajektorije javljaju se i konstantni nemjerljivi poremećaji. Ako dinamički sustav (objekt regulacije) ne posjeduje integralno djelovanje, nije u mogućnosti otkloniti statičku pogrešku. Isto tako ako sustav posjeduje astatizam a izostalo je integralno djelovanje regulatora nije moguće otkloniti moguće konstantne nemjerljive poremećaje duž trajektorije praćenja. Stoga je svakako nužno kod dinamičkih sustava nultog astatizma osim već navedenog proporcionalno-derivacijskog djelovanja (5.1) definirati i integralno djelovanje. Stoga dolazimo do Linearnog **PID**-zakona upravljanja u slijedećem obliku [57,58]

$$u_r(t) = K_p e + K_i \int e(t) dt + K_v \frac{de}{dt} = K_p \left[e(t) + \frac{1}{T_i} \int e(t) dt + T_D \frac{de(t)}{dt} \right], \quad (5.45)$$

gdje je K_i konstanta pojačanja, a T_i vremenska konstanta integracijskog djelovanja. Ako matematičkim formalizmom integral prethodnog izraza zamijenimo zbrojem pravokutnika širine T_s i visine $e(nT_s)$, a prema Ojleru prvu derivaciju drugom vrstom diferencija dobiva se

$$u_r(n) = K_p \left(e(n) + \frac{T_s}{T_i} \sum_{i=1}^n e(n) + \frac{T_D}{T_s} \Delta e(n) \right). \quad (5.46)$$

Prethodno dobiveni izraz u $(n-1)$ koraku glasi

$$u_r(n-1) = K_p \left(e(n-1) + \frac{T_s}{T_I} \sum_{i=1}^{n-1} e(n-1) + \frac{T_D}{T_s} \Delta e(n-1) \right) . \quad (5.47)$$

S obzirom na strukturu dobivenog izraza, lako je uvidjeti da se razlikom prethodna dva izraza dobiva diskretni ekvivalent kontinuiranom linearnom **PID** zakonu upravljanja (5.45) u inkrementalnom obliku

$$\Delta u_r(n) = K_p \left(\Delta e(n) + \frac{T_s}{T_I} e(n) + \frac{T_D}{T_s} \Delta^2 e(n) \right) , \quad (5.48)$$

gdje su prva i druga diferencija dani izrazima:

$$\Delta e(n) = e(n) - e(n-1) , \quad \Delta^2 e(n) = e(n) - 2e(n-1) + e(n-2) . \quad (5.49)$$

Iz dobivenog izraza (5.48) neposredno slijedi pozicioni oblik diskretnog ekvivalenta linearnom **PID**-zakonu upravljanja u obliku

$$u_r(n) = u_r(n-1) + K_p \left(\Delta e(n) + \frac{T_s}{T_I} e(n) + \frac{T_D}{T_s} \Delta^2 e(n) \right) . \quad (5.50)$$

Na temelju dobivenih izraza (5.48) i (5.50) sasvim se intuitivno nameće definicija inkrementalnog i pozicionog oblika **PI**-regulatora u diskretnom području kako slijedi

$$\Delta u_r(n) = K_p \left(\Delta e(n) + \frac{T_s}{T_I} e(n) \right) , \quad (5.51)$$

$$u_r(n) = u_r(n-1) + K_p \left(\Delta e(n) + \frac{T_s}{T_I} e(n) \right) . \quad (5.52)$$

PI i **PID** pozicioni zakoni upravljanja (5.50 i 5.52) se implementiraju sa ciljem eliminiranja mogućih konstantnih nemjerljivih vanjskih poremećaja ili statičke pogreške kod dinamičkih sustava nultog astatizma. Kod dinamičkih sustava kod kojih se ne javlja potreba za eliminiranjem vanjskih konstantnih nemjerljivih poremećaja, odnosno kod sustava koji posjeduju integralno djelovanje, otklonjena je statička pogreška te se stoga koriste inkrementalni oblici **PI** i **PID** zakona upravljanja (5.48 i 5.51), npr. u sustavima sa koračnim motorom kao izvršnim organom. Usporedbom **PD** i inkrementalnog **PI** zakona upravljanja (5.1, 5.51) sasvim je evidentna njihova jednakost strukture, koja je uz definirane pogreške pozicije $e(n)$ i brzine $\Delta e(n)$ kao ulaznih varijabli uz različite vrijednosti pojačanja naročito pogodna sa stajališta implementacije. Stoga se diskretnom obliku **PI**-zakona upravljanja analogno definira neizraziti analitički regulator **PI**-djelovanja u svom inkrementalnom obliku

$$\Delta u_{FI}(n+1) = K_I \Psi(\underline{e}, \underline{de}, n) , \quad (5.53)$$

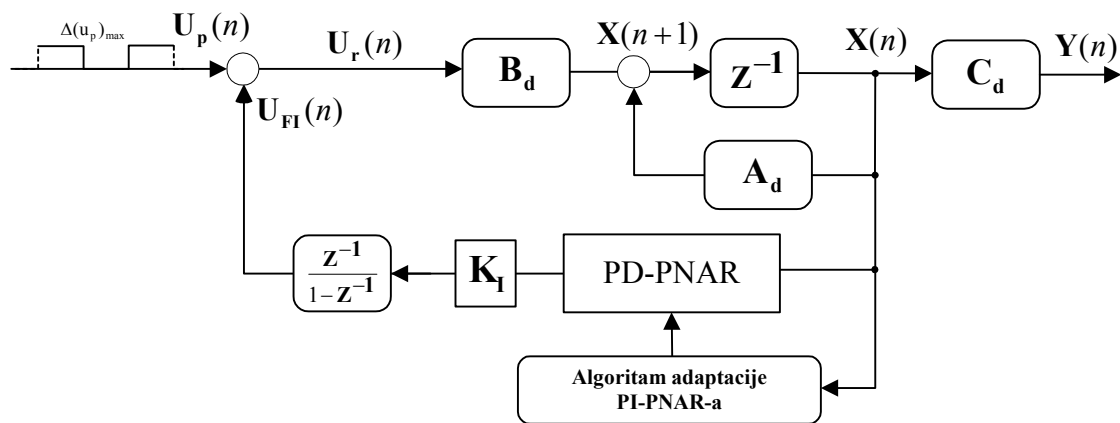
koji je uz vrijednost integracijskog pojačanja $K_I=1$ po strukturi jednak **PD-PNAR**-u (5.3), ali ima različite vrijednosti definiranih slobodnih F i β parametara. Sintezom linearnog **PI** regulatora postavljanjem polova u željene lokacije Gausove kompleksne ravnine $\lambda_1=-1,274$, $\lambda_2=-7$ i $\lambda_3=-10$ dolazimo do potrebnih parametara familija karakterističnih krivulja ulaznih varijabli pogreške pozicije $K_{np}=2,78$ i brzine $K_{nv}=2,85$ **NAR**-a. Početnim podešavanjem **PI-PNAR**-a (poglavlje 3) dolazimo do njegovih parametara

$$F_e=0,156 \quad \beta_e=0,028 \quad F_{de}=0,162 \quad \beta_{de}=0,0287 \quad |e|_{\max}=1 \quad |de|_{\max}=1 \quad U_{\max}=15 \text{ V} . \quad (5.54)$$

Sa tim parametrima **PI-PNAR** se ponaša kao nelinearni ekvivalent (5.53), diskretnom linearnom **PI**-regulatoru u inkrementalnom obliku (5.51). U svrhu otklanjanja konstantnih nemjerljivih vanjskih poremećaja potrebno je definirati pozicioni oblik **PI-PNAR**-a u obliku

$$u_{FI}(n+1) = u_{FI}(n) + K_I \Psi(e, de, n) , \quad (5.55)$$

što je prikazano na (slici 5.12).



Slika 5.12 Model adaptacije slobodnih parametara **PI-PNAR**-a pri vrijednosti integracijskog pojačanja $K_I=1$ i maksimalne procijenjene vrijednosti vanjskog konstantnog poremećaja $(\Delta u_p)_{\max}$.

Uz procijenjenu vrijednost konstantnih nemjerljivih vanjskih poremećaja $\Delta(u_p)_{\max}$, potrebno je algoritmom adaptacije odrediti slobodne parametre **PI-PNAR**-a, sa zadatkom što bržeg eliminiranja statičke pogreške. U tu svrhu generira se impulsnim pravokutnim signalom svake 4s vanjski poremećaj amplitude Δq_{\max} , sveden na stranu neizrazitog regulatora u vrijednosti amplitude $\Delta(u_p)_{\max}=0,7\text{V}$ (slika 5.12). Pritom se definira algoritam adaptacije isti kao i kod **PD-PNAR**-a danim izrazima (5.14), ali sa novo odabranim koeficijentima brzine učenja danim u (tablici 5.2).

parametri	e	de
δ_{F1}	2,4	0,3
δ_{F2}	-0,4	-0,05
$\delta_{\beta 1}$	-36,0	-4,39
$\delta_{\beta 2}$	6,01	0,73


Tablica 5.2 Koeficijenti brzine učenja nelinearnog algoritma adaptiranja početno ugođenog **PI-PNAR-a**

Koeficijenti brzine učenja su odabrani u skladu sa postavljenim odnosima (5.16). Jedina razlika u odnosu na prethodno definirani algoritam adaptacije (5.14) je u koeficijentima učenja koji se ovdje definiraju kao

$$\hat{\delta}_{Fe(i)} = \delta_{Fe(i)} e^{\sigma_1 \frac{ISE_1 - ISE}{ISE_1}}, \quad \hat{\delta}_{Fde(i)} = \delta_{Fde(i)} e^{\sigma_2 \frac{ISE_2 - ISE}{ISE_2}}, \quad i=1,2. \quad (5.56)$$

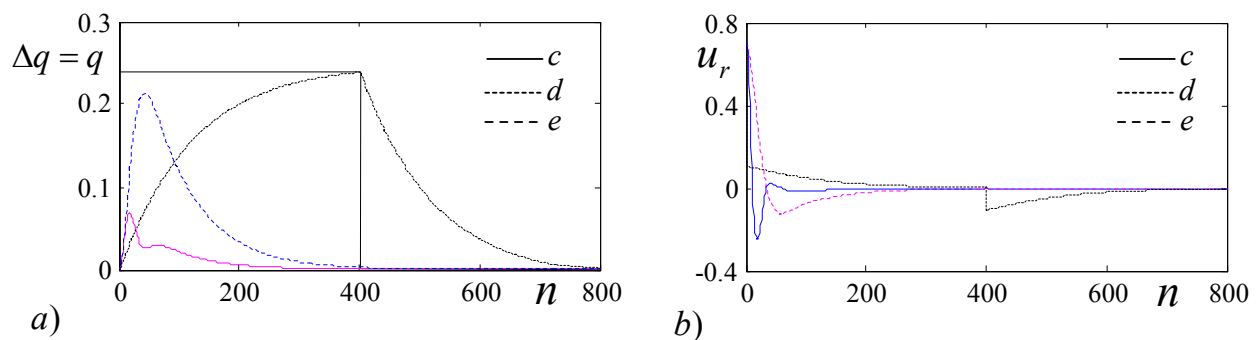
Prikladnim odabirom vrijednosti integralnih kriterija kvadrata pogreške (4.18), $ISE_1 \cong ISE_2 \cong ISE = 0,047$ i $\sigma_1=2$, $\sigma_2=1$, postiže se da su u strogom smislu postavljena ograničenja (5.38-39) pri odabiru koeficijenata brzine učenja i dalje važeća. Pritom je uvijek bolje odabrati koeficijente brzine učenja još manjih vrijednosti od graničnih vrijednosti dobivenih ograničenjima (5.38-39) čime se na račun smanjenja brzine konvergencije povećava stupanj stabilnosti algoritma adaptacije. Uz odabranu vrijednost integralnog kriterija kvadratne pogreške $ISE=0,0015$, algoritam adaptacije se zaustavlja nakon 81 iteracije (slika 5.13), pri čemu je za zadani dinamički sustav (slika 5.12), upravljačka površina neizrazitog analitičkog **PI**-regulatora oblikovana sa konačno postignutim parametrima

$$F_e=4,56 \quad \beta_e=9,79 \cdot 10^{-4} \quad F_{de}=0,9 \quad \beta_{de}=5,19 \cdot 10^{-3}. \quad (5.57)$$



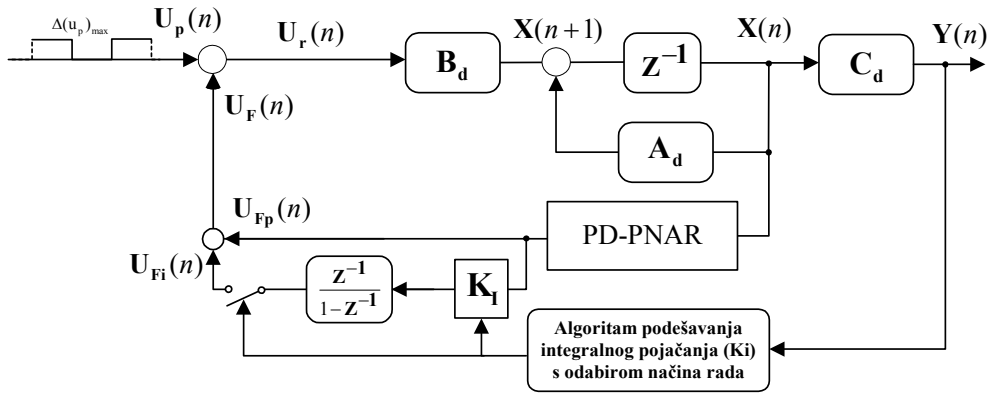
Slika 5.13 Grafički prikaz vrijednosti ISE pozicije (3.18) po iteracijama (promjenama reference) pri procesu adaptacije slobodnih parametara **PI-PNAR-a**.

Smanjenje integralnog kriterija kvadrata pogreške pozicije (ISE) po iteracijama prikazano je dijagramom na (slici 5.13). Implementiranjem **PI-PNAR**-a u inkrementalnom obliku (5.53), za posljedicu ima postojanje statičke pogreške Δq_{max} , koju nije moguće otkloniti (slika 5.14a, (-d)), o čemu govori i upravljačka varijabla na ulazu dinamičkog sustava koja je u periodu djelovanja poremećaja monotono opadajuća funkcija vremena (slika 5.14b, (-d)). Implementacijom **PI-PNAR**-a u pozicionom obliku u periodu poremećaja, uspješno se eliminira vrijednost statičke pogreške izlazne varijable. Početno ugođeni **PI-PNAR** sa dobivenim parametrima (5.54) vrši emulaciju linearnog **PI**-zakona upravljanja pri čemu pogreška iščezava tokom vremena kako je prikazano dijagramom (slika 5.14a, (-e)).



Slika 5.14 Grafički prikaz ostvarene trajektorije a) i upravljačke varijable na ulazu objekta regulacije b), uslijed djelovanja konstantnog nemjerljivog vanjskog poremećaja od strane implementiranog **PD-PNAR**-a (-d), i implementiranog **PI-PNAR**-a na početku (-e) i na kraju procesa adaptacije (-c).

Pritom upravljačka varijabla posjeduje integralno djelovanje što se očituje njezinom skokovitom promjenom u trenutku nastanka poremećaja (slika 5.14b, (-e)). Za zadani dinamički sustav (objekt regulacije + regulator), oblik upravljačke površine $\Psi(\underline{e}, \underline{d}, n)$, određen je postupkom adaptacije slobodnih parametara **PI-PNAR**-a. Djelovanjem tako generirane upravljačke varijable (Slika 5.14b, (-c)), daleko brže i bez prebačaja eliminira se vanjski nemjerljivi poremećaj konstantnog iznosa (slika 5.14a, (-c)), gdje je pritom maksimalna vrijednost pogreške približno tri puta manja nego na početku adaptacije. Ako pođemo od već dobivene strukture neizrazitog analitičkog **PD**-regulatora sa usvojenim F i β parametrima (5.17) dobivenim postupkom adaptacije (5.14), onda se do integralnog djelovanja regulatora, na jednostavan način može doći paralelnim dodavanjem integracijskog djelovanja izlazu postojećeg **PD-PNAR**-a (slika 5.15) [60,61,62]. U ovom slučaju potrebno je jedino podešavanje integralnog pojačanja (K_I) za razliku od **PI-PNAR**-a gdje je nužno potrebno provesti postupak adaptiranja slobodnih F i β parametara.



Slika 5.15 Struktura modela odstupanja od željene referentne trajektorije pri djelovanju konstantnih nemjerljivih vanjskih poremećaja $(\Delta u_p)_{max}$ uz mogućnost podešavanja integralnog pojačanja implementiranog **PID-PNAR**-a

Neizrazitu vrijednost upravljačke veličine sada dobivamo u obliku

$$u_F(n+1) = u_{Fp}(n+1) + u_{Fi}(n+1) \quad . \quad (5.58)$$

Kako vrijedi

$$u_{Fp}(n+1) = \Psi(e, \underline{de}, n+1) \quad , \quad (5.59)$$

onda uz izraz (5.55) dolazimo do neizrazite upravljačke varijable u konačnom rekurzivnom obliku

$$u_F(n+1) = u_{Fi}(n) + K_I \Psi(e, \underline{de}, n) + \Psi(e, \underline{de}, n+1) \quad . \quad (5.60)$$

Sa stajališta odstupanja od referentne trajektorije na osnovu izraza (5.55) definira se potrebna promjena integralne neizrazite upravljačke varijable zadužene za eliminiranje konstantnog nemjerljivog vanjskog poremećaja duž trajektorije

$$\Delta u_{Fi}(n+1) = \Delta u_{Fi}(n) + K_I \Delta \Psi(e, \underline{de}, F, \beta, n) \quad . \quad (5.61)$$

Uz izraz (4.8) prethodni izraz dobiva oblik

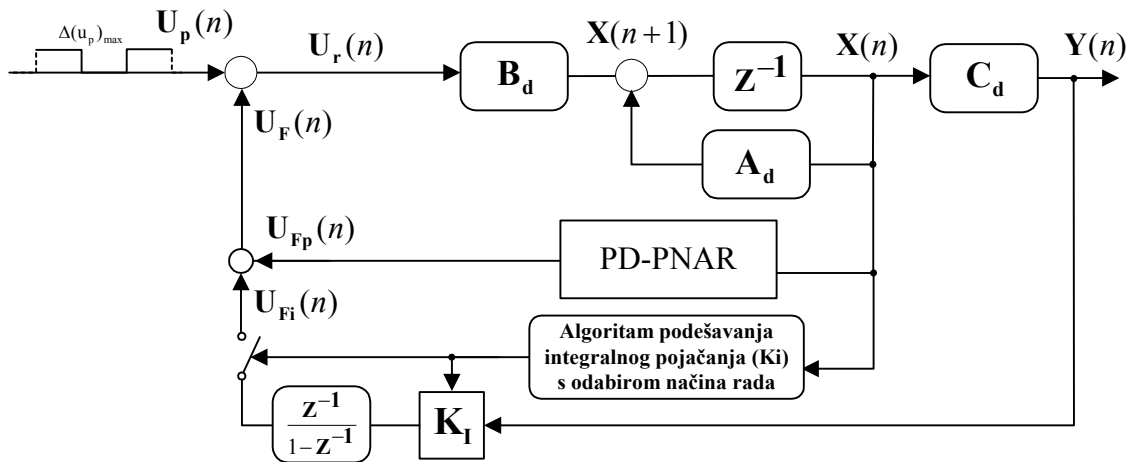
$$\Delta u_{Fi}(n+1) = \Delta u_{Fi}(n) + K_I (\Theta_{F_e} \Delta F_e + \Theta_{\beta_e} \Delta \beta_e + \Theta_{F_{de}} \Delta F_{de} + \Theta_{\beta_{de}} \Delta \beta_{de})_n \quad , \quad (5.62)$$

ili konačno

$$\Delta^2 u_{Fi}(n+1) = K_I (\Theta_{F_e} \Delta F_e + \Theta_{\beta_e} \Delta \beta_e + \Theta_{F_{de}} \Delta F_{de} + \Theta_{\beta_{de}} \Delta \beta_{de})_n \quad , \quad (5.63)$$

što je uz važeći izraz (4.8) u skladu sa izrazom (5.53). Dakle sa stajališta odstupanja od referentne trajektorije, promjena F i β parametara ulaznih varijabli pogreške pozicije i brzine, u svrhu eliminiranja vanjskih konstantnih nemjerljivih poremećaja definira se drugom diferencijom. Izrazom (5.60) definirana je jedna od mogućih varijanti **PID** djelovanja neizrazitog analitičkog regulatora. Druga varijanta integracijskog djelovanja po pogreški pozicije moguća je

paralelnim dodavanjem klasičnog integracijskog člana [60,61,62] postojećem **PD-PNAR**-u već utvrđenih parametara (slika 5.16).



Slika 5.16 Struktura modela odstupanja od željene referentne trajektorije pri djelovanju konstantnih nemjerljivih vanjskih poremećaja $(\Delta u_p)_{\max}$ uz mogućnost podešavanja integralnog pojačanja paralelno dodanog klasičnog integralnog člana **PD-PNAR**-u parametara (5.17).

U tom slučaju ukupno **PID** djelovanje na osnovu izraza (5.58) zapisuje se u pozicionom obliku

$$u_F(n+1) = u_{FI}(n) + K_I e(n) + \Psi(e, de, n+1) \quad , \quad (5.64)$$

gdje u slijedećem normaliziranom vremenski diskretnom koraku integracijsku komponentu dobivamo izrazom

$$u_{FI}(n+1) = u_{FI}(n) + K_I e(n) \quad . \quad (5.65)$$

Prethodni izraz zajedno s izrazom (5.60), polazna su osnova za podešavanje integralnog pojačanja K_I . Podešavanje integralnog pojačanja zasniva se na eliminiranju ili svođenju statičke pogreške na kraju perioda djelovanja poremećaja ispod unaprijed zadane vrijednosti. Ako vrijednost statičke pogreške izlazne generalizirane varijable q u posljednjem periodu uzorkovanja (n^*) na kraju n -te iteracije označimo sa $\Delta e^*(n^*) = -\Delta q(n^*)$, onda se prirast integralnog pojačanja $\Delta K_I(n)$ u svrhu eliminiranja preostale statičke pogreške u n -toj iteraciji može definirati kao

$$\Delta K_I(n) = \theta^{-1}(n^*) \Delta e^*(n^*) \quad , \quad (5.66)$$

gdje je sa $\theta(n^*)$ označena parcijalna derivacija poopćene varijable po integralnom pojačanju, a predstavlja osjetljivost izlazne varijable o integralnom pojačanju u posljednjem periodu uzorkovanja (n^*) . Kako su izlaz i upravljačka varijabla sustava u pravilu kontinuirane funkcije vremena osjetljivost se u kontinuiranom području definira uzastopnim parcijalnim derivacijama

$$\theta(t) = \frac{\partial q(t)}{\partial K_I} = \frac{\partial q(t)}{\partial u_r(t)} \frac{\partial u_r(t)}{\partial K_I} . \quad (5.67)$$

U slučaju sustava sa jednom ulaznom i jednom izlaznom varijablom (**SISO**-sustavi), parcijalna derivacija izlazne varijable o upravljačkoj varijabli u Laplasovom području jednaka je prijenosnoj funkciji sustava. Kod **MIMO** - sustava kao što je to model mobilnog robota [38,40] uslijed dinamičkog sprežanja između pojedinih stupnjeva slobode gibanja izlazna i-ta varijabla je funkcija oba dvije upravljačke varijable servosustava. U tom slučaju prethodni izraz glasi

$$(\theta_{KI})_i = \left(\frac{\partial q}{\partial K_I} \right)_i = \frac{\partial q_i}{\partial (u_r)_i} \frac{\partial (u_r)_i}{\partial (K_I)_i} + \frac{\partial q_i}{\partial (u_r)_j} \frac{\partial (u_r)_j}{\partial (K_I)_j} , \quad i=1,2 \quad \& \quad i \neq j , \quad (5.68)$$

gdje su osjetljivosti upravljačke varijable o integralnom pojačanju definirane parcijalnom derivacijom

$$(\Theta_{KI})_i = \frac{\partial (u_r)_i}{\partial (K_I)_i} , \quad i=1,2 . \quad (5.69)$$

U općenitom slučaju izraz (5.68) sadrži onoliko pribrojnika koliko je ulaznih varijabli, odnosno stupnjeva slobode gibanja, a svaki sa osjetljivošću ulazne upravljačke varijable o pripadajućem integralnom pojačanju doprinosi ukupnoj osjetljivosti i-te izlazne varijable o i-tom integralnom pojačanju. Pritom parcijalna derivacija i-te izlazne varijable o upravljačkoj j-toj varijabli predstavlja komponentu g_{ij} prijenosne matrice **G** multivarijabilnog sustava

$$\mathbf{G} = \mathbf{C}[\mathbf{sI} - \mathbf{A}]^{-1} \mathbf{B} . \quad (5.70)$$

Dinamika promjene osjetljivosti i-te izlazne varijable o i-tom integralnom pojačanju odgovara dinamici varijabli stanja multivarijabilnog sustava, stoga se može pisati da vrijedi:

$$\begin{bmatrix} \dot{\theta}_{KI1} & \dot{\theta}_{KI2} & \ddot{\theta}_{KI1} & \ddot{\theta}_{KI2} \end{bmatrix}^T = \mathbf{A} \begin{bmatrix} \theta_{KI1} & \theta_{KI2} & \dot{\theta}_{KI1} & \dot{\theta}_{KI2} \end{bmatrix}^T + \mathbf{B} \begin{bmatrix} \Theta_{KI1} & \Theta_{KI2} \end{bmatrix}^T . \quad (5.71)$$

Uslijed slabog dinamičkog sprežanja između pojedinih stupnjeva slobode i malih brzina gibanja mobilnog robota referentnom trajektorijom, može se uzeti da je osjetljivost i-te izlazne varijable funkcija osjetljivosti samo i-te ulazne upravljačke varijable. Stoga sa stajališta raspregnute dinamike može se pisati

$$\ddot{q}(t) = -KQ\dot{q}(t) + KRK_{Pu}u_r(t) , \quad (5.72)$$

gdje $K_{Pu}=6$ predstavlja pojačanje naponskog pojačala snage. Djelovanjem parcijalne derivacije $\partial/\partial K_I$ nad prethodnim izrazom dolazi se do dinamike izlazne osjetljivosti $\theta(t)$ o osjetljivosti ulazne upravljačke varijable $\Theta_{KI}(t)$ opisane u vremenskom području

$$\ddot{\theta}(t) = -KQ\dot{\theta}(t) + KRK_{Pu}\Theta_{KI}(t) , \quad (5.73)$$

gdje se KR i KQ dobivaju izrazima (4.50). Prethodni izraz dan prostorom stanja u diskretnom području glasi

$$\begin{bmatrix} \theta(n+1) & \dot{\theta}(n+1) \end{bmatrix}^T = \mathbf{A}_{di} \begin{bmatrix} \theta(n) & \dot{\theta}(n) \end{bmatrix}^T + \mathbf{B}_{di} K_{pu} \Theta_{KI}(n+1) \quad , \quad (5.74)$$

gdje se uz izraze (4.46) prvom Ojlerovom varijantom dobivaju komponente diskretnih matrica

$$\mathbf{A}_{di} = [\mathbf{I} + T_s \mathbf{A}_i] \quad , \quad \mathbf{B}_{di} = T_s \mathbf{B}_i \quad . \quad (5.75)$$

Zapisivanjem izraza (5.67) u diskretnom području za $(n+1)$ normalizirani vremenski diskretni korak diskretizacije uz izraz (5.69) se dobiva

$$\theta(n+1) = \frac{\partial q(n+1)}{\partial K_I} = \frac{\partial q(n+1)}{\partial u_r(n+1)} \Theta_{KI}(n+1) \quad , \quad (5.76)$$

što predstavlja direktnu vezu sa izrazom (5.74), na osnovu kojeg se dobiva rješenje prethodnog izraza i izlazna osjetljivost po integralnom pojačanju u $(n+1)$ normaliziranom vremenski diskretnom koraku. Kako općenito vrijedi da je upravljačka varijabla dobivena sumiranjem signala

$$u_r(n+1) = u_p(n+1) + u_{Fp}(n+1) + u_{FI}(n+1) \quad , \quad (5.77)$$

onda uz izraz (5.69) iz prethodnog izraza neposredno slijedi

$$\Theta_{KI}(n+1) = \frac{\partial u_r(n+1)}{\partial K_I} = \frac{\partial u_{FI}(n+1)}{\partial K_I} \quad . \quad (5.78)$$

Iz izraza (5.65) slijedi da se u slučaju paralelno dodanog klasičnog integralnog člana **PD-PNAR**-u (slika 5.16) osjetljivost upravljačke varijable o integralnom pojačanju dobiva izrazom

$$\Theta_{KI}(n+1) = \Theta_{KI}(n) + e(n) \quad , \quad (5.79)$$

dok se u slučaju formiranja dodatnog integracijskog signala (5.55) sa izlaza postojećeg **PD-PNAR-a** (slika 5.15) osjetljivost upravljačke varijable o integralnom pojačanju dobiva kao


$$\Theta_{KI}(n+1) = \Theta_{KI}(n) + \Psi(\underline{e}, \underline{de}, n) \quad . \quad (5.80)$$

Prethodno dobiveni izrazi (5.79-80) zajedno sa izrazom (5.74) izračunavaju se u svakom normaliziranom vremenski diskretnom koraku i samim tim su osnova za izračunavanje integralnog pojačanja u posljednjem n^* tom koraku na kraju n -te iteracije, pri čemu vrijednost integralnog pojačanja u slijedećoj $(n+1)$ iteraciji dobivamo izrazom (5.66)

$$K_I(n+1) = K_I(n) + \theta^{-1}(n^*) \Delta e^*(n^*) \quad . \quad (5.81)$$

Impulsnim pravokutnim signalom svake sekunde generira se nemjerljiva konstantna vanjska poremećajna veličina maksimalnog iznosa svedena na stranu regulatora u procijenjenom iznosu od 0,7 V. U tom periodu aktivira se integracijsko djelovanje regulatora, tako da je u trenutku nastanka poremećaja integralno pojačanje regulatora nultog iznosa a njegovo podešavanje vrši se

u posljednjem n^* -tom koraku svakog perioda poremećajnog djelovanja dok se apsolutna vrijednost pogreške ne smanji ispod unaprijed zadanog minimalnog iznosa koji se ovdje uzima da je $\Delta e^*_{\max} = 0,005$. Zbog nulte vrijednosti integralnog pojačanja koje se uzima u prvoj iteraciji ostvarena trajektorija pozicije ne prati željenu referentnu vrijednost već poprima vrijednost amplitude izlazne poremećajne veličine (slika 5.17a, (-d)), za razliku od uvedenog integracijskog djelovanja sa vrijednosti integralnog pojačanja dobivenog na kraju podešavanja, gdje neposredno nakon djelovanja poremećaja trajektorija pozicije vraća se u ravnotežno stanje. U slučaju paralelno uvedenog integracijskog signala (5.55) izlazu **PD-PNAR**-a (slika 5.15), nakon 57 iteracija dolazi se do vrijednosti integralnog pojačanja $K_I=3,35$. Trajektorija pozicije vraća se svome ravnotežnom stanju nešto brže nego u slučaju djelovanja klasičnog integralnog člana (slika 5.17a, (-c)). Vrijednost potrebnog integralnog pojačanja u slučaju formiranja integracijskog signala (5.65) paralelnim dodavanjem klasičnog integralnog člana **PD-PNAR**-u (slika 5.16) je dobivena nakon 19 iteracija i jednaka je $K_I=27,25$ (slika 5.17a, (-e)). U tim slučajevima iz prikazanih dijagrama upravljačke varijable (slika 5.17b) već je u početnom trenutku poremećajnog djelovanja uočljivo integracijsko djelovanje.

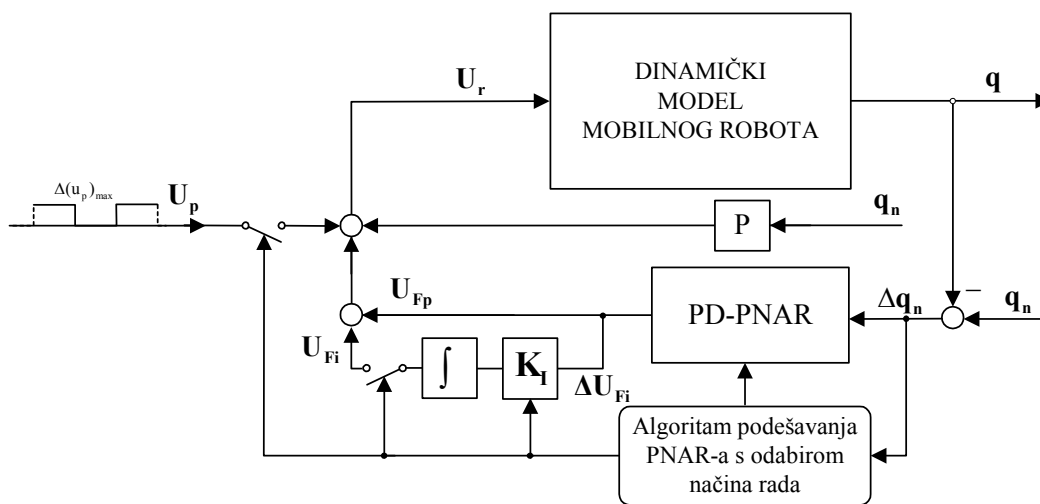


Slika 5.17 *Dijagrami ostvarene trajektorije a) i upravljačke varijable b), uslijed djelovanja vanjskog konstantnog nemjerljivog poremećaja na početku podešavanja sa implementiranim **PD-PNAR**-om (-d), i na završetku podešavanja integralnog pojačanja uz paralelno uvedeni integracijski signal od strane klasičnog integracijskog člana (-e), (slika 5.16) i izlaza **PD-PNAR**-a (-c), (slika 5.15).*

Iz prikazanih mogućih struktura **PID**-djelovanja neizrazitog analitičkog regulatora (slike 5.15-16) predloženim algoritmima integracijskog djelovanja dana je mogućnost podešavanja integralnog pojačanja i u **ON**-line modu uklapanjem integracijskog djelovanja samo onda kada vrijednost statičke pogreške poraste iznad dozvoljene unaprijed zadane vrijednosti $\Delta e^*_{\max} = 0,005$.

5.6 Strukture samoorganiziranja PNAR-a

Kao što je pokazano u podpoglavlju 2.4 nelinearna struktura **PNAR**-a posjeduje izrazito nelinearna proporcionalno derivacijska svojstva. Početnim podešavanjem (ugađanjem) postiže se stanje minimalne pobuđenosti **PNAR**-a, čije djelovanje je blisko klasičnom linearnom **PD** regulatoru kao što je pokazano u poglavlju 3. Postupkom početnog ugađanja **PNAR**-a započet je postupak samoorganiziranja njegovih slobodnih F i β parametara u OFF-line modu rada. Pritom se početne nulte vrijednosti parametara skokovito mijenjaju do vrijednosti dobivenih predloženim algoritmom početnog podešavanja **PNAR**-a (slika 3.5). Na taj način neizrazita upravljačka ploha se dovodi u početni položaj, sa svojstvima koji je približavaju linearnom **PD**-regulatoru u prostoru stanja. U skladu sa postavljenim zadatkom regulacije u daljnjem postupku provodi se fina adaptacija slobodnih F i β parametara (4.23), pri čemu se oblikuje neizrazita upravljačka ploha **PNAR**-a s maksimalno naglašenim progresivnim nelinearnim djelovanjem. U općem slučaju kod obje predložene strukture samoorganiziranja **PNAR**-a prikazane na slikama 5.18 i 5.19 proces adaptacije slobodnih parametara završava kada se diskretna vrijednost integrala kvadratne pogreške, koji se računa na kraju svake iteracije integralnim kriterijem (4.18) nađe ispod unaprijed zadane vrijednosti.



Slika 5.18 *Struktura samoorganiziranja s paralelno uvedenim klasičnim integralnim članom, izlazu PD-PNAR-a.*

Zatim se dolazi do nove strukture s integralnim djelovanjem i definiranim integralnim pojačanjem K_I čija se vrijednost podešava algoritmom predloženim u prethodnom podpoglavlju. Stoga neovisno o predloženoj strukturi samoorganiziranja na osnovu izraza (4.23 i 5.66)

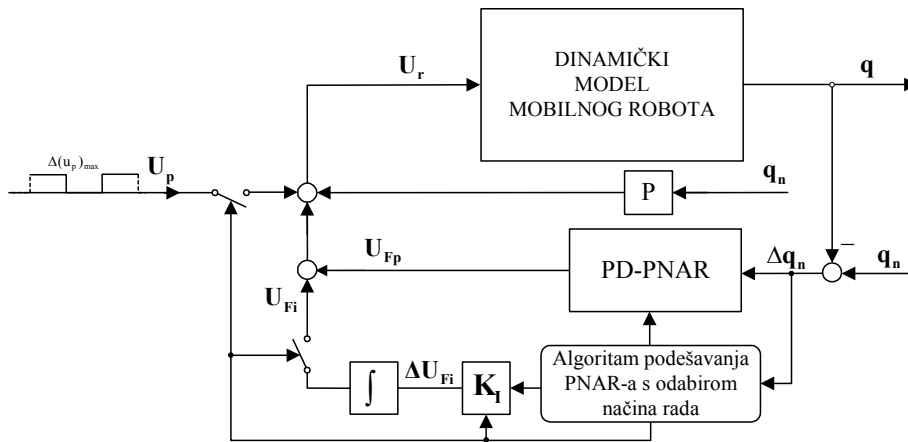
postupak samoorganiziranja na nivou (i)-tog stupnja slobode gibanja za $j=1,2,3$, $k=1,2$ definira se u svom konačnom obliku

$$\Delta \mathcal{G}_j^{(i)}(n) = -\eta_{gjk}^{(i)} \Theta_{gjk}^{(i)} \Delta q_k^{(i)}(n) \xi + \alpha_{gjk}^{(i)} \Delta \mathcal{G}_j^{(i)}(n-1) \xi + \theta^{-1(i)}(n^*) \Delta e^{*(i)}(n^*) (1-\xi) \quad , \quad (5.82)$$

gdje diskretna varijabla ξ pri procesu adaptacije slobodnog j -tog parametara **PNAR**-a je jednaka jedinici. Kada vrijednost integrala kvadratne pogreške koja se računa izrazom (4.18) padne ispod zadane vrijednosti dolazi se do nulte vrijednosti diskretne varijable ξ . Pritom dolazi do uključenja emulacije vanjskog nemjerljivog poremećaja u procijenjenom konstantnom iznosu pri čemu na kraju n -te iteracije u posljednjem n^* tom koraku dolazi do podešavanja integralne vrijednosti pojačanja K_I . Stoga paralelnim dodavanjem klasičnog integralnog člana izlazu postojećeg **PD-PNAR**-a dolazi se do predložene strukture samoorganiziranja **PNAR**-a dane na slici 5.18. U tom slučaju neizrazita vrijednost upravljačke varijable dobiva se izrazom

$$u_F(n+1) = u_{FI}(n)(1-\xi) + K_I \Psi(e, \underline{de}, n)(1-\xi) + \Psi(e, \underline{de}, n+1) \quad . \quad (5.83)$$

Da bi se nakon završenog procesa adaptacije F i β parametra eliminirala preostala pogreška **PD-PNAR**-a uvodi se integralno djelovanje promjenom strukture ($\xi=0$) s zadatkom da se emulirana procijenjena pogreška stacionarnog stanja svede na nulu ili da ostane u granicama dopuštenih vrijednosti.



Slika 5.19 *Struktura samoorganiziranja **PD-PNAR**-a s paralelno uvedenim klasičnim integralnim članom.*

Do strukture samoorganiziranja **PNAR**-a prikazane na slici 5.19. dolazi se paralelnim dodavanjem klasičnog integralnog člana **PD-PNAR**-u pri čemu se neizrazita vrijednost upravljačke varijable dobiva izrazom

$$u_F(n+1) = u_{FI}(n)(1-\xi) + K_I e(n)(1-\xi) + \Psi(e, \underline{de}, n+1) \quad . \quad (5.84)$$

Iz različitosti predloženih struktura samoorganiziranja **PNAR**-a prikazanih na slikama 5.18 i 5.19 neposredno slijedi i različitost u pogledu neizrazitog upravljačkog djelovanja, koja se vidi iz formirane neizrazite vrijednosti upravljačke varijable dane izrazima (5.83-84). Iako je na prvi pogled postupak samoorganiziranja slobodnih F i β parametara i integralne vrijednosti pojačanja K_I dan izrazom (5.82) za obje strukture samoorganiziranja isti, ipak sadržana je implicitna različitost u izračunavanju osjetljivosti izlazne varijable o integralnom pojačanju, a do koje se u slučaju predloženih struktura samoorganiziranja dolazi navedenim izrazima (5.74, 5.79 i 5.80). Podešenom integralnom vrijednošću pojačanja završava se postupak samoorganiziranja **PNAR**-a pri čemu je završeno i dodatno oblikovanje neizrazite upravljačke površine progresivnog djelovanja. Dakle jedanput provedenim postupkom samoorganiziranja, podešavanjem slobodnih parametara u **OFF**-line modu rada, dolazi se do statičke vremenski invarijantne upravljačke strukture **PNAR**-a u **ON**-line modu rada.

6. PNAR PRILAGOĐEN ON-LINE VOĐENJU MOBILNOG ROBOTA U REALNOM VREMENU

Vođenje mobilnog robota referentnom putanjom ostvaruje se na nivou unutarnjih upravljanih koordinata ($i=1,2$), nelinearnim zakonom upravljanja

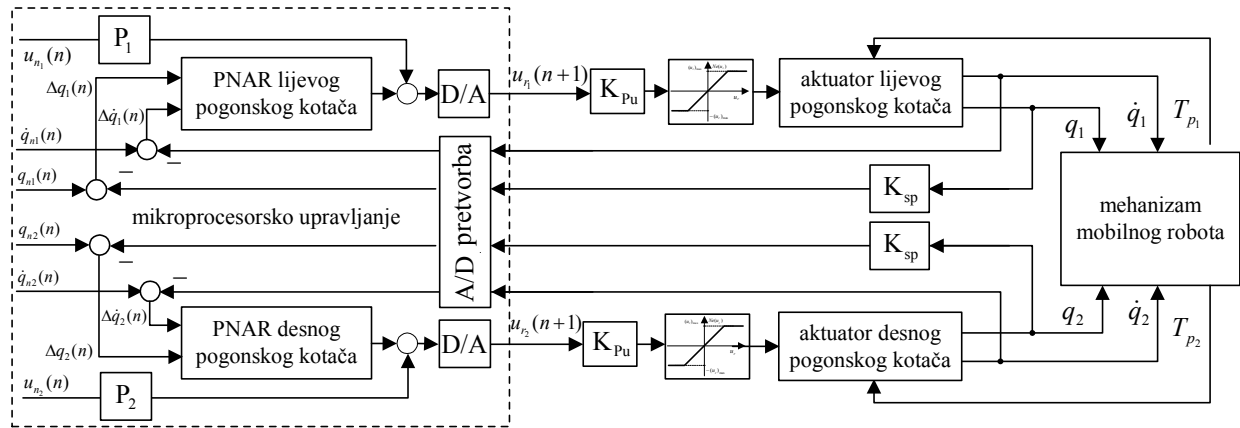
$$(u_r)_i = \Psi_i(e, de) + P_i(u_n)_i, \quad i=1,2, \quad (6.1)$$

implementiranim u mikroprocesoru digitalnog računala. Mikroprocesorskom realizacijom neizraziti regulator posjeduje sva svojstva digitalnog regulatora (slika 6.1) [80]. Na osnovu izlaznih pogreški pozicije (e) i brzine (de) u pojedinim vremenskim trenucima uzorkovanja $t=(t_o, t_o+T_s, t_o+2T_s \dots, t_o+nT_s)$ predloženim algoritmom **PNAR**-a (poglavlje 2) izračunava se vrijednosti upravljačkih varijabli $(u_r)_i$ na ulazu servosustava zadužene za i -te stupnjeve slobode gibanja mobilnog robota. Sa stajališta matematičkih računskih operacija koje je potrebno izvršiti u svakom periodu uzorkovanja (T_s) signala, predloženi algoritam neizrazite regulacije je relativno složene strukture. Općenito vrijeme uzorkovanja T_s signala mora biti dovoljno veliko da bi se u tom periodu uspješno obavile sljedeće potrebne aktivnosti:

- a) Prije ulaska signala u digitalno računalo, potrebno je izvršiti **Analogno-Digitalnu** pretvorbu (**A/D**) signala sa senzora za koje je potreban period vremena T_{AD} .
- b) Za učitavanje, iščitavanje i normiranje ulazno izlaznih podataka iz računala, kao i za sam proces izračunavanja upravljačke varijable obradom algoritma neizrazitog upravljanja potreban je period vremena T_p .
- c) Upravljačka varijabla djeluje preko naponskog pojačala snage na kontinuirani izvršni element upravljanja (istosmjerni servomotor), te je stoga neposredno nakon njezinog izračunavanja u računalu potrebno izvršiti u definiranom periodu vremena T_{DA} , **Digitalno-Analognu** pretvorbu (**D/A**) upravljačke varijable (slika 6.1).

Na osnovu svega rečenog potrebno je zadovoljiti uvjet [80]

$$T_s \geq T_{AD} + T_p + T_{DA} \quad (6.2)$$



Slika 6.1 *Struktura mikroprocesorskog vođenja mobilnog robota sa implementiranim PNAR-om kao nelinearnim algoritmom upravljanja u prostoru unutarnjih upravljanih koordinata.*

Dakle na ulazu i izlazu računala pretvorba signala se vrši **A/D** odnosno **D/A** pretvornicima pri čijem izboru broja bita kao i broju bita mikroprocesora treba posvetiti određenu pažnju kako bi se zadovoljili traženi uvjeti točnosti. Npr. korištenjem 12 bitovnog pretvarača vrijednost jednog bita je 0,00366V, što približno odgovara 0,024 % od maksimalne vrijednosti upravljačke varijable $\pm 15V$. U slučaju 12 bitovnog pretvarača pogreška **A/D** i **D/A** pretvorbe je manja od 0,00366V što je u granicama traženih uvjeta točnosti pri kojima se može zanemariti utjecaj diskretizacije po amplitudi kako ulaznih varijabli tako i izlazne upravljačke varijable neizrazitog analitičkog regulatora s obzirom na kvalitetu odziva. Dakle na točnost amplitudne diskretizacije preko **A/D** i **D/A** pretvornika prvenstveno se utječe odabirom broja bita dok je vrijeme trajanja **A/D** i **D/A** konverzije unaprijed određeno izvedbom pretvornika i na njega se ne može direktno utjecati. Iz postavljenog ograničenja danog izrazom (6.2) vidljivo je da je uz poznato potrebno ukupno vrijeme konverzije signala ($T_{AD}+T_{DA}$), period uzorkovanja T_s prvenstveno određen vremenom izračunavanja upravljačke varijable odnosno vremenskim periodom izvršavanja neizrazitog algoritma upravljanja T_p . Kako je neizraziti nelinearni algoritam upravljanja dan izrazima (2.30-31) relativno složene strukture koji se izvršava u svakom normaliziranom vremenski diskretnom koraku $n=1,2,\dots,N$, onda je povećanje brzine rada prvenstveno vezano uz nastojanja da se određenim pojednostavljenjima u strukturi nelinearnog algoritma upravljanja ide ka smanjenju procesorskog vremena T_p potrebnog za izračunavanje upravljačke varijable. U tu svrhu vrši se diskretizacija ulaznih varijabli neizrazitog analitičkog regulatora slijedećim definiranim funkcijama

$$f(e) = \text{sgn}(e) \text{round}(e/e_b)e_b \quad , \quad f(\underline{de}) = \text{sgn}(\underline{de}) \text{round}(\underline{de}/\underline{de}_b)\underline{de}_b \quad , \quad (6.3)$$

u kojima e_b i de_b predstavljaju pogreške pozicije i brzine koje odgovaraju jednom bitu uslijed diskretizacije a $\text{round}(\cdot)$ označava funkciju zaokruživanja dane varijable unutar zagrada. Normalizirane vrijednosti pogreške pozicije \underline{e} i brzine \underline{de} kao elementi skupova $\underline{e} \in \{-1, \dots, e/|e|_{\max}, \dots, 1\}$, $\underline{de} \in \{-1, \dots, de/|de|_{\max}, \dots, 1\}$, za koje općenito vrijedi $\underline{e}, \underline{de} \subset R$ s prethodno definiranim funkcijama $f(\underline{e}) : \underline{e} \subset R \rightarrow \underline{e}^* \subset R$, $f(\underline{de}) : \underline{de} \subset R \rightarrow \underline{de}^* \subset R$ preslikavaju se u elemente skupova diskretnih normaliziranih vrijednosti \underline{e}^* i \underline{de}^*

$$\begin{aligned} \underline{e}^* &= \{-2^n e_b, -(2^n - 1)e_b, \dots, -e_b, 0, e_b, \dots, (2^n - 1)e_b, 2^n e_b\}, \\ \underline{de}^* &= \{-2^n de_b, -(2^n - 1)de_b, \dots, -de_b, 0, de_b, \dots, (2^n - 1)de_b, 2^n de_b\}, \end{aligned} \quad (6.4)$$

ili se s novo uvedenim funkcijama $f(\underline{e})/e_b : \underline{e} \subset R \rightarrow \underline{e}^* \subset Z$, $f(\underline{de})/de_b : \underline{de} \subset R \rightarrow \underline{de}^* \subset Z$ se vrši preslikavanje u diskretne elemente koji čine podskup cijelih brojeva

$$\underline{e}^* \in \{-2^n, -2^n + 1, \dots, -1, 0, 1, \dots, 2^n - 1, 2^n\} \quad \underline{de}^* \subseteq \underline{e}^* \quad (6.5)$$

Općenito kod diskretizacije varijable važno je koliko iznosi njezin inkrementalni dio, jer to za zadanu vrijednost varijable predstavlja raspon vrijednosti gubitka informacije, između dviju susjednih diskretiziranih vrijednosti. Uz osam bitovnu diskretizaciju ($\hat{n}=8$) vrijednost jednog bita je 0,0039, koja je ujedno i najmanje moguća diskretna vrijednost normalizirane vrijednosti pogreške pozicije i brzine kao ulaznih varijabli neizrazitog regulatora. Formiranjem uređenih parova $(\underline{e}^*, \underline{de}^*)$ kao kartezijevog produkta svih elemenata skupova (6.4), uz predloženi algoritam upravljanja se izračunavanjem dolazi do vrijednosti upravljačkih varijabli u obliku tablice sa $(2^{n+1} + 1) \times (2^{n+1} + 1)$ diskretnih elemenata kao što je to prikazano na (slici 6.2).

$u_F(e^*(k), de^*(j))$		$e^*(k) \quad \text{gdje je} \quad k=1,2,\dots,k_{\max}=2^{\hat{n}+1}+1 \quad i \quad j=1,2,\dots,j_{\max}=2^{\hat{n}+1}+1$									
	$j \backslash k$	$-2^{\hat{n}}$	$-2^{\hat{n}}+1$	\cdots	-1	0	1	\cdots	$2^{\hat{n}}-1$	$2^{\hat{n}}$	
	$-2^{\hat{n}}$	$u_F(-2^{\hat{n}}, -2^{\hat{n}})$	$u_F(-2^{\hat{n}}+1, -2^{\hat{n}})$	\cdots	$u_F(-1, -2^{\hat{n}})$	$u_F(0, -2^{\hat{n}})$	$u_F(1, -2^{\hat{n}})$	\cdots	$u_F(2^{\hat{n}}-1, -2^{\hat{n}})$	$u_F(2^{\hat{n}}, -2^{\hat{n}})$	
$de^*(j)$	$-2^{\hat{n}}+1$	$u_F(-2^{\hat{n}}, -2^{\hat{n}}+1)$	$u_F(-2^{\hat{n}}+1, -2^{\hat{n}}+1)$	\cdots	$u_F(-1, -2^{\hat{n}}+1)$	$u_F(0, -2^{\hat{n}}+1)$	$u_F(1, -2^{\hat{n}}+1)$	\cdots	$u_F(2^{\hat{n}}-1, -2^{\hat{n}}+1)$	$u_F(2^{\hat{n}}, -2^{\hat{n}}+1)$	
	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	
	-1	$u_F(-2^{\hat{n}}, -1)$	$u_F(-2^{\hat{n}}+1, -1)$	\cdots	$u_F(-1, -1)$	$u_F(0, -1)$	$u_F(1, -1)$	\cdots	$u_F(2^{\hat{n}}-1, -1)$	$u_F(2^{\hat{n}}, -1)$	
	0	$u_F(-2^{\hat{n}}, 0)$	$u_F(-2^{\hat{n}}+1, 0)$	\cdots	$u_F(-1, 0)$	0	$u_F(1, 0)$	\cdots	$u_F(2^{\hat{n}}-1, 0)$	$u_F(2^{\hat{n}}, 0)$	
	1	$u_F(-2^{\hat{n}}, 1)$	$u_F(-2^{\hat{n}}+1, 1)$	\cdots	$u_F(-1, 1)$	$u_F(0, 1)$	$u_F(1, 1)$	\cdots	$u_F(2^{\hat{n}}-1, 1)$	$u_F(2^{\hat{n}}, 1)$	
	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	
	2^n-1	$u_F(-2^{\hat{n}}, 2^{\hat{n}}-1)$	$u_F(-2^{\hat{n}}+1, 2^{\hat{n}}-1)$	\cdots	$u_F(-1, 2^{\hat{n}}-1)$	$u_F(0, 2^{\hat{n}}-1)$	$u_F(1, 2^{\hat{n}}-1)$	\cdots	$u_F(2^{\hat{n}}-1, 2^{\hat{n}}-1)$	$u_F(2^{\hat{n}}, 2^{\hat{n}}-1)$	
	2^n	$u_F(-2^{\hat{n}}, 2^{\hat{n}})$	$u_F(-2^{\hat{n}}+1, 2^{\hat{n}})$	\cdots	$u_F(-1, 2^{\hat{n}})$	$u_F(0, 2^{\hat{n}})$	$u_F(1, 2^{\hat{n}})$	\cdots	$u_F(2^{\hat{n}}-1, 2^{\hat{n}})$	$u_F(2^{\hat{n}}, 2^{\hat{n}})$	

Slika 6.2 Formiranje memorijske kvadratne matrice (tablice) $\dim(2^{\hat{n}+1} + 1)$ neizrazite upravljačke varijable

Rezultat amplitudne diskretizacije ulaznih varijabli poboljšanog neizrazitog analitičkog regulatora je tablica upravljačkih varijabli koju zovemo memorijskom karticom željenog upravljačkog djelovanja pri vođenju mobilnog robota referentnom putanjom (prilog 6). Upravljačka varijabla na ovaj način formira se približno dvadeset puta brže nego analitičkim putem korištenjem nelinearnog algoritma upravljanja (2.30-31). Neposredno nakon samoorganiziranja slobodnih parametara **PNAR**-a u **OFF**-line modu rada ponavljanjem upravljačkog algoritma za svaki uređeni par ulaznih varijabli ($e^* de^*$) formira se memorijska kvadratna matrica (tablica) neizrazitih upravljačkih varijabli (slika 6.2) koja se zatim učitava u memoriju mikroprocesora. Pri **ON**-line modu rada iz memorijske lokacije određene izrazima (6.4) unutar svakog normaliziranog vremenski diskretnog koraka (n) očitava se vrijednost neizrazite upravljačke varijable koja se zatim u obliku programskog signala (u_p) zajedno sa unaprijednim djelovanjem (u_n) uvodi kao upravljačka varijabla preko naponskog pojačala snage na i -ti servomotor. Nasuprot dobroj strani amplitudne diskretizacije koja se očituje u brzini rada, ovdje treba istaknuti i njen osnovni nedostatak koji se manifestira gubitkom određenog broja podataka i mogućnosti promjene kako pogreški tako i upravljanih varijabli (pozicije i brzine) do konačnih minimalnih vrijednosti određenih jednim bitom što se uz postavljene zahtjeve minimalnog odstupanja od referentne trajektorije može negativno očitovati na kakvoću vođenja mobilnog robota. Stoga se pristupa modifikaciji navedenog pristupa u tom smislu što se određeni gubitak informacije između diskretiziranih vrijednosti nastoji nadomjestiti aproksimacijskom upravljačkom plohom koja prolazi kroz točke $u_F(e^*(k), de^*(j))$ definirane memorijskom karticom (slika 6.2), tako da pri ostalim vrijednostima ulaznih varijabli (e, de) odstupanje tako dobivene upravljačke varijable $u_F(e, de)$ od stvarne vrijednosti definirane nelinearnim algoritmom upravljanja (2.30-31) bude minimalno i ravnomjerno raspoređeno po cijeloj memorijskoj kartici. Zadanim vrijednostima pogreške pozicije (e) i brzine (de) kao ulaznih varijabli **PNAR**-a, te aktivacijskim funkcijama $f(e)/e_b$ i $f(de)/de_b$ danim izrazima (6.3) aktiviraju se redom najbliže memorijske lokacije $\{e^*(k), de^*(j)\}$, $\{e^*(k+k^*), de^*(j)\}$ i $\{e^*(k), de^*(j+j^*)\}$, sa upravljačkim varijablama u_{F0} , u_{F1} i u_{F2} (slika 6.3a). Indeksi k^* i j^* pritom poprimaju diskretne vrijednosti -1, 0 i 1 dobivene izrazima

$$k^* = \text{sign}(e - e^*(k)) \quad , \quad j^* = \text{sign}(de - de^*(j)) \quad . \quad (6.6)$$


Nad lokacijom aktiviranom sa tri upravljačke varijable

$$\begin{aligned} u_{F0} &= u_F(e^*(k), de^*(j)) = u_F(k, j) \quad , \\ u_{F1} &= u_F(e^*(k+k^*), de^*(j)) = u_F(k+k^*, j) \quad , \end{aligned} \quad (6.7)$$

$$u_{F2} = u_F(e^*(k), de^*(j + j^*)) = u_F(k, j + j^*) ,$$

polaze se aproksimacijska upravljačka ravnina (slika 6.3b), pomoću koje se dobiva aproksimirana vrijednost upravljačke varijable izrazom (prilog 7)

$$u_F = u_F(k, j) + \Delta K_e(e - e^*(k)) + \Delta K_{de}(de - de^*(j)) . \quad (6.8)$$



Slika 6.3 a) Aktiviranje memorijskih lokacija ulaznim varijablama (e^* , de^*) te prikaz polaganja aproksimacijske upravljačke površine nad aktiviranim memorijskim lokacijama upravljačke kartice b).

Ovdje su sa ΔK_e i ΔK_{de} označene vrijednosti dinamičkih pojačanja koje ujedno predstavljaju i nagibe upravljačke plohe prema osama fiktivnog pomičnog koordinatnog sustava sa ishodištem u aktivnoj upravljačkoj varijabli u_{F0} (slika 6.3b) i u ovom slučaju se definiraju izrazima

$$\Delta K_{Fe} = \frac{u_{F1} - u_{F0}}{\Delta e(k)} , \quad \Delta K_{Fde} = \frac{u_{F2} - u_{F0}}{\Delta de(j)} , \quad (6.9)$$

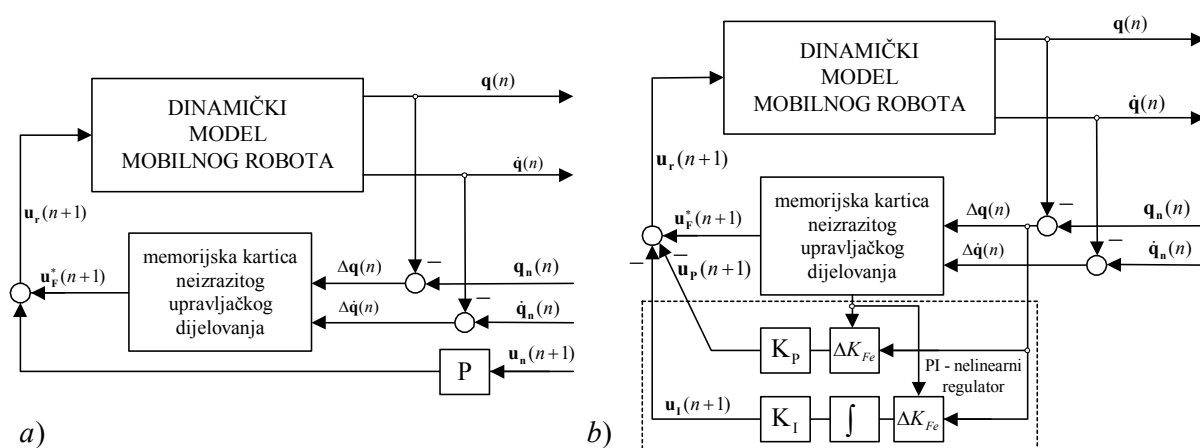
gdje $\Delta e(k)$ i $\Delta de(j)$ označavaju inkrementalni prirast pogreške pozicije odnosno brzine koja odgovara vrijednosti jednog bita. Osnovna modifikacija u predloženom pristupu dana je izrazom (6.8), koji na osnovu tri poznate vrijednosti upravljačke varijable očitane iz memorijske kartice uz minimalni broj računskih operacija izračunava vrijednost upravljačke varijable. Ako još uz to kažemo da se i vrijednosti dinamičkih pojačanja definiranih izrazom (6.9) mogu izračunati jednom za svagda prije samog početka rada neizrastog regulatora i očitavati iz memorije računala, onda je posve jasno da predloženi algoritam aproksimacijske upravljačke plohe (6.8) svojom dužinom izvođenja minimalno povećava ukupno trajanje predloženog algoritma vođenja. Treba istaknuti da sa komercijalnog stajališta ovako dobivena **Memorijska Kartica Neizrastog Upravljačkog Djelovanja (MKNUD)** zbog svoje relativno jednostavne implementacije ima

veliko značenje pri vođenju tehničkih objekata u realnom vremenu. Osim jednostavne komercijalne »čipovske« mikrokontrolerske implementacije **MKNUD** služi i kao baza podataka za razvoj sofisticiranijih algoritama upravljanja kao što su Umjetne Neuronske Mreže (UNM) [63,64,66] i Genetski Algoritmi (GA) [65]. U daljem nastavku izlaganja biti će predložena nova moguća poboljšanja [67], s prikazanim rezultatima simulacije vođenja mobilnog robota s instaliranom **MKNUD** u realnom vremenu.

6.1 Rezultati simulacije ON-line vođenja mobilnog robota u realnom vremenu sa implementiranom **MKNUD**-a


Za formiranje memorijske kartice neizrazitog upravljačkog djelovanja potrebno je redom izvršiti slijedeće osnovne aktivnosti

- Početno podešavanje (ugađanje) poboljšanog neizrazitog analitičkog regulatora **PD-PNAR**-a, (poglavlje 3)
- Pri zadanoj trajektoriji gibanja mobilnog robota potrebno je provesti postupak adaptiranja slobodnih (F i β) parametara izloženom modificiranom gradijentnom metodom, (poglavlje 4).
- Tvorba **Memorijske Kartice Neizrazitog Upravljačkog Djelovanja (MKNUD)** i njezino učitavanje zajedno sa vrijednostima dinamičkih pojačanja (6.9) u obliku memorijskih blokova u mikroprocesoru (poglavlje 6).




Slika 6.4 Prikaz upravljačke strukture pri **ON**-line vođenju mobilnog robota u realnom vremenu sa implementiranom **MKNUD** a), i implementiranim nelinearnim **PI**-regulatorom b).

Nakon tvorbe **MKNUD** pristupa se definiranju upravljačke strukture za **ON**-line vođenje mobilnog robota u prostoru unutarnjih upravljanih koordinata u realnom vremenu (slika 6.4a). Za već odabranu referentnu trajektoriju određenu točkama (T_1, T_2, \dots, T_7) (Slika 3.8) i slobodne F i β parametre dobivene samoorganiziranjem **PD-PNAR**-a (3.1.1) a integriranih u **MKNUD**, redom se uz vrijeme uzorkovanja $T_s=10$ ms prikazuju dijagrami izlazne pogreške pozicije (slika 6.5) i brzine (slika 6.6) servosustava lijevog i desnog pogonskog kotača.



Slika 6.5 Dijagram izlazne pogreške pozicije servosustava lijevog i desnog pogonskog kotača, pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8) sa implementiranom **MKNUD**-a (slika 6.4a).




Slika 6.6 Dijagram izlazne pogreške brzine servosustava lijevog i desnog pogonskog kotača, pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8) sa implementiranom **MKNUD**-a (slika 6.4a).


Kod upravljačke strukture sa integriranom **MKNUD** ukupna se upravljačka varijabla definira kao

$$u_r(n+1) = u_F^*(e(n), de(n)) + Pu_n(n+1) \quad (6.10)$$

gdje je P pojačanje unaprijednog djelovanja $u_n(n+1)$, dok je sa $u_F^*(e(n), de(n))$ označena neizrazita upravljačka veličina koja se izračunava izrazom (6.8) na osnovu formirane **MKNUD**. Vrijednosti ukupne upravljačke varijable po normaliziranim vremenski diskretnim koracima (n) prikazane su dijagramom (slika 6.7).




Slika 6.7 Dijagramski prikaz neizrazite upravljačke varijable (6.10) istosmjernih servosustava lijevog i desnog pogonskog kotača pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8), sa **MKNUD**-a (slika 6.4a).



Slika 6.8 Dijagramski prikaz promjene vrijednosti dinamičkog pojačanja pozicije (6.9), pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8) i sa implementiranom **MKNUD**-a (slika 6.4a).

Svako odstupanje pogreške pozicije i brzine od nulte vrijednosti rezultira promjenom vrijednosti dinamičkog pojačanja pozicije i brzine kao što je to prikazano dijagramima na slici 6.8 i 6.9. Veće odstupanje pozicije i brzine od nominalnih vrijednosti rezultira većim promjenama dinamičkih pojačanja.



Slika 6.9 Dijagramski prikaz promjene vrijednosti dinamičkog pojačanja brzine (6.9), pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8) i sa implementiranom **MKNUD**-a (slika 6.4a).


Na osnovu definicionih izraza dinamičkog pojačanja pozicije i brzine (6.9) sasvim je evidentno da većim prirastima upravljačke varijable po inkrementu pogreške odgovaraju i veća dinamička pojačanja. Odavde i proizlazi izrazito nelinearno djelovanje upravljačke strukture (slika 6.4a).

6.2 Rezultati simulacije ON-line vođenja mobilnog robota u realnom vremenu sa implementiranom MKNUD-a i izrazito nelinearnim PI-regulatorom

Sa osnovnim zadatkom što manjeg odstupanja od referentne trajektorije pri **ON**-line vođenju mobilnog robota iskorištavajući pritom nelinearnosti sadržane u vrijednostima dinamičkih pojačanja pozicije (slika 6.8) pristupa se poboljšanju postojeće upravljačke strukture (slika 6.4a) paralelnim uvođenjem nelinearnog **PI**-regulatora po poziciji, postojećoj **MKNUD**-a (slika 6.4b). Upravljačka varijabla nelinearnog P-djelovanja dana je izrazom

$$u_p(n+1) = K_p \Delta K_{Fe}(e) \Delta e(n) \quad , \quad (6.11)$$

gdje je K_p konstanta pojačanja pozicije a $\Delta K_{Fe}(e)$ je dinamička nelinearna vrijednost pojačanja pozicije. Uz vrijednost konstante pojačanja pozicije $K_p=7,4$ proporcionalni dio djelovanja nelinearnog **PI** regulatora pri **ON**-line vođenju mobilnog robota referentnom putanjom (slika 3.8), uz vrijeme uzorkovanja $T_s=10$ ms, prikazano je dijagramom na slici 6.10.




Slika 6.10 *Dijagramski prikaz upravljačke varijable nelinearnog **P** djelovanja (6.11) implementirane upravljačke strukture (slika 6.4b) pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8).*

Integralni dio djelovanja po poziciji nelinearnog **PI**-regulatora dan je integralnom komponentom upravljačke varijable u obliku

$$u_I(n+1) = u_I(n) + K_I \Delta K_{Fe}(e) \Delta e(n) \quad , \quad (6.12)$$


koji je, uz odabranu vrijednost integracijskog pojačanja $K_I=18$, prikazan dijagramom slika 6.11. Za razliku od upravljačke strukture prikazane na slici 6.4a, upravljačka struktura s implementiranim nelinearnim **PI** regulatorom astatičke je prirode. Ova struktura, osim

otklanjanja poremećaja početnih uvjeta, posjeduje i mogućnost otklanjanja konstantnih nemjerljivih vanjskih poremećaja.



Slika 6.11 Dijagramski prikaz upravljačke varijable nelinearnog **I** djelovanja (6.12) implementirane upravljačke strukture (slika 6.4b) pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom sa (slika 3.8).

Zbog astatičkog regulacijskog djelovanja kod ove strukture nije potrebno unaprijedno djelovanje, što je potpuno evidentno djelovanjem integralne upravljačke komponente (slika 6.11). Neizrazita komponenta upravljačke varijable $u_F^*(e(n), de(n))$, u periodu uzorkovanja $T_s=10$ ms na osnovu očitanih podataka iz **MKNUD**-a, izračunava se izrazom (6.8). Njezine vrijednosti po normaliziranim vremenski diskretnim koracima (n) prikazuju se slijedećim dijagramom.




Slika 6.12 Dijagramski prikaz neizrazite upravljačke komponente izračunate izrazom (6.8), na osnovu podataka iz **MKNUD**-a upravljačke strukture (slika 6.4b), pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8).

Ukupno upravljačko djelovanje upravljačke strukture (slika 6.4b), dano je sumom nelinearne proporcionalne (6.11), integralne (6.12) i neizrazite upravljačke komponente


$$u_r(n+1) = K_p \Delta K_{Fe}(e) \Delta e(n) + u_I(n+1) + u_F^*(e(n), de(n)) \quad , \quad (6.13)$$

a prikazano je po normaliziranim vremenski diskretnim koracima na slici 6.13.




Slika 6.13 Dijagramski prikaz ukupne nelinearne upravljačke varijable (6.13) implementirane upravljačke strukture (slika 6.4b) pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8).

U odnosu na upravljačku strukturu (slika 6.4a), novo predložena poboljšana upravljačka struktura s implementiranim nelinearnim **PI**-regulatorom ima daleko bolja upravljačka svojstva. Maksimalna pogreška po poziciji smanjila se je preko šest puta (slika 6.14).



Slika 6.14 Dijagram izlazne pogreške pozicije pogonskih kotača pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8), i s implementiranom upravljačkom strukturom (slika 6.4b).

Međutim pogreška po brzini zadržala se je u relativno jednakim granicama, a prikazana je slijedećim dijagramom (slika 6.15).



Slika 6.15 Dijagram izlazne pogreške brzine pogonskih kotača pri **ON**-line vođenju mobilnog robota u realnom vremenu referentnom trajektorijom (slika 3.8), s implementiranom upravljačkom strukturom (slika 6.4b).

6.3 ON-line vođenje mobilnog robota u realnom vremenu uz djelovanje stacionarnog poremećaja tipa »bijelog šuma«

Osim poremećaja tipa početnih uvjeta i konstantnih nemjerljivih vanjskih poremećaja na objekt regulacije djeluju i različiti poremećaji tipa stohastičke prirode. Takve je poremećaje teško predvidjeti, te u velikom broju slučajeva svaki stohastički dinamički sustav zahtjeva individualni pristup kako u analizi tako i u poduzimanju određenih mjera u sprječavanju nastanka i djelovanja takvih slučajnih poremećaja. Pritom se razlikuju vanjski i unutarnji poremećaji stohastičke prirode [74]. Ako vanjske poremećaje koji uzimaju u obzir vanjski šum označimo kao kontinuiranu funkciju vremena $v(t)$ koja djeluje na ulazu dinamičkog sustava, a unutarnji šum (smetnju) koja djeluje na izlazu istog sustava sa $w(t)$, dolazi se do dinamičkog sustava mobilnog robota u sljedećem obliku [78]:

$$\dot{\mathbf{X}}(t) = \mathbf{A}\mathbf{X}(t) + \mathbf{B}(\mathbf{U}(t) + \mathbf{V}(t)) \quad , \quad \mathbf{Y}(t) = \mathbf{C}\mathbf{X}(t) \quad , \quad \mathbf{X}(t=0) = \mathbf{X}(0) = \mathbf{X}_0 \quad , \quad (6.14)$$

$$\tilde{\mathbf{Y}}(t) = \mathbf{C}\mathbf{X}(t) + \mathbf{W}(t) \quad . \quad (6.15)$$

U prethodnim jednadžbama je sa $\tilde{\mathbf{Y}}(t)$ označen vektor mjernih izlaza, koji se razlikuje od vektora izlaza $\mathbf{Y}(t)$ za interne smetnje (mjerni šum) $\mathbf{W}(t)=[w_1(t) \ w_2(t)]^T$. Iz tog razloga jednadžbu (6.15) zovemo jednadžbom mjernih izlaza ili opservacionom jednadžbom [74], a $\mathbf{Y}(t)$ jednadžbom izlaza koja se dobiva kad na izlazu promatranog dinamičkog sustava ne djeluju smetnje (6.14). Vanjski šum (smetnja) s komponentama $\mathbf{V}(t)=[v_1(t) \ v_2(t)]^T$ još se naziva i inducirana smetnja a posljedica je rada drugih tehničkih naprava iz bliže ili dalje okoline. Karakteristike smetnji dane su statističkim pokazateljima (parametrima), a jedan od najvažnijih dobiva se djelovanjem funkcije matematičkog očekivanja, ili srednje vrijednosti $M\{\cdot\}$ nad komponentama (n) dimenzionalnog vektora šuma. Tako se u slučaju dvodimenzionalnog (dvokanalnog) vanjskog i internog šuma dobivaju njihove srednje vrijednosti komponenata označene potezom kako slijedi

$$M\{\mathbf{V}(t)\} = \bar{\mathbf{V}}(t) = [\bar{v}_1(t) \ \bar{v}_2(t)]^T \quad , \quad M\{\mathbf{W}(t)\} = \bar{\mathbf{W}}(t) = [\bar{w}_1(t) \ \bar{w}_2(t)]^T \quad . \quad (6.16)$$

Slijedeći statistički parametar po važnosti definiran je matricom korelacije (kovarijance), koja se dobiva funkcijom kovarijance $\text{Kov}\{\cdot\}$ između dva slučajna vektora smetnje u slijedećem obliku

$$\text{Kov}\{\mathbf{V}(t), \mathbf{W}(\tau)\} = V_{\mathbf{VW}}(t, \tau) = M\left\{[\mathbf{V}(t) - \bar{\mathbf{V}}(t)][\mathbf{W}(\tau) - \bar{\mathbf{W}}(\tau)]^T\right\} = \mathbf{S}(t)\delta(t - \tau) \quad , \quad (6.17)$$

u kojem se skraćenim načinom pisanja $V_{\mathbf{VW}}(t, \tau)$ označava funkciju kovarijance između slučajnih vektora $\mathbf{V}(t)$ i $\mathbf{W}(t)$, dok $\delta(t - \tau)$ predstavlja translatiranu Dirakovu (Diracovu) funkciju poznatu sa svim svojim svojstvima još i kao Kroneckerova (Kroneckerova) delta

funkcija [57,58,75]. Pozitivnom semidefinitnom kovarijancnom matricom $\mathbf{S}(t) \geq 0$ dim(2x2) preko njezinih definiranih komponenata

$$S_{ij} = M \{ [v_i(t) - \bar{v}_i(t)] [w_j(\tau) - \bar{w}_j(\tau)] \} , \quad i,j=1,2 , \quad (6.18)$$

dana je statistička zavisnost (korelacija) i -te komponente vektora vanjskog šuma $\mathbf{V}(t)$ koji djeluje na ulazu sa j -tom komponentom vektora mjernog šuma $\mathbf{W}(t)$ na izlazu stohastičkog procesa. U slučaju izostanka statističke zavisnosti između tih vektora matrica korelacije $\mathbf{S}(t)$ je nul matrica. Ako se kompletna smetnja stohastičkog sustava (6.14-15) sagleda kroz kompletni slučajni vektor smetnji $\mathbf{Z}(t)=[\mathbf{V}(t) \ \mathbf{W}(t)]^T$, onda se nakon primjene prethodno definirane funkcije kovarijance dobiva [79]

$$V_{\mathbf{Z}\mathbf{Z}}(t, \tau) = \text{Kov}\{\mathbf{Z}(t), \mathbf{Z}(\tau)\} = \begin{bmatrix} V_{\mathbf{V}\mathbf{V}}(t, \tau) & V_{\mathbf{V}\mathbf{W}}(t, \tau) \\ V_{\mathbf{W}\mathbf{V}}(t, \tau) & V_{\mathbf{W}\mathbf{W}}(t, \tau) \end{bmatrix} = \tilde{\mathbf{V}}(t) \delta(t - \tau) . \quad (6.19)$$

Kovarijancne matrice vektora vanjskog i mjernog šuma definirane su redom

$$V_{\mathbf{V}}(t, \tau) = V_{\mathbf{V}\mathbf{V}}(t, \tau) = M \{ [\mathbf{V}(t) - \bar{\mathbf{V}}(t)] [\mathbf{V}(\tau) - \bar{\mathbf{V}}(\tau)]^T \} = \mathbf{Q}(t) \delta(t - \tau) , \quad (6.20)$$

$$V_{\mathbf{W}}(t, \tau) = V_{\mathbf{W}\mathbf{W}}(t, \tau) = M \{ [\mathbf{W}(t) - \bar{\mathbf{W}}(t)] [\mathbf{W}(\tau) - \bar{\mathbf{W}}(\tau)]^T \} = \mathbf{R}(t) \delta(t - \tau) . \quad (6.21)$$

Kao slijedeći važan statistički parametar dane su prethodnim izrazima matrice varijance koje se dobivaju kao poseban slučaj djelovanja funkcije kovarijance slučajnog vektora nad samim sobom. Pozitivno semidefinitna simetrična matrica varijance $\mathbf{Q}(t)=\mathbf{Q}^T(t) \geq 0$ vektora vanjske smetnje $\mathbf{V}(t)$ i pozitivno definitna simetrična matrica varijance $\mathbf{R}(t)=\mathbf{R}^T(t) > 0$ vektora mjernog šuma $\mathbf{W}(t)$ redom su definirane svojim komponentama

$$Q_{ij} = M \{ [v_i(t) - \bar{v}_i(t)] [v_j(\tau) - \bar{v}_j(\tau)] \} , \quad R_{ij} = M \{ [w_i(t) - \bar{w}_i(t)] [w_j(\tau) - \bar{w}_j(\tau)] \} , \quad i,j=1,2. \quad (6.22)$$

U slučaju postojanja izvan dijagonalnih elemenata matrica $\mathbf{Q}(t)$ i $\mathbf{R}(t)$ radi se o »obojanom šumu« pri čemu u nekom vremenskom trenutku postoji statistička zavisnost (korelacija) između vrijednosti komponenata slučajnog vektora. To znači da su vrijednosti komponenti slučajnog vektora zavisni o njihovim vrijednostima u prethodnim trenucima vremena. Ako u različitim vremenskim trenucima ne postoji bilo kakve uzajamne zavisnosti između slučajnih vektora, kao i međusobne zavisnosti između vrijednosti komponenata slučajnog vektora u promatranom vremenskom trenutku matrice varijance $\mathbf{Q}(t)$ i $\mathbf{R}(t)$ poprimaju dijagonalnu formu.

$$\mathbf{Q}(t) = \text{diag}[\sigma_{Q_i}^2] , \quad \mathbf{R}(t) = \text{diag}[\sigma_{R_i}^2] , \quad i=1,2 , \quad (6.23)$$

čiji elementi predstavljaju varijancu odnosno kvadrat standardnog odstupanja σ^2 kao mjere disperzije (rasipanja) smetnje oko srednje vrijednosti. U tom slučaju se radi o smetnji tipa »bijelog šuma«. Na osnovu izraza (6.17; 6.19-21) dolazimo do matrice varijance $\tilde{\mathbf{V}}(t)$, koja je uz

prethodno definirane vektore srednje vrijednosti (6.16), još jedan važan pokazatelj karakteristika smetnji promatranog stohastičkog procesa

$$\tilde{\mathbf{V}}(t) = \begin{bmatrix} \mathbf{Q}(t) & \mathbf{S}(t) \\ \mathbf{S}^T(t) & \mathbf{R}(t) \end{bmatrix} . \quad (6.24)$$

Kako je u praksi automatske regulacije najčešće prisutna smetnja tipa »bijelog šuma« u nastavku će biti izložena metodologija vođenja mobilnog robota uz dominantno djelovanje interne smetnje (»bijelog šuma«) koja proizlazi od mjernih instrumenata. U tom slučaju prethodno definirana matrica varijance čitavog stohastičkog procesa je blok dijagonalne forme sa elementima glavne dijagonale koji odgovaraju komponentama (6.23). U promatranom vremenskom trenutku amplitude komponenata vektora mjernog »bijelog šuma« posjeduju normalnu razdiobu, odnosno gustoću vjerojatnosti p prema Gausovoj normalnoj raspodjeli [72]


$$p_{\mathbf{w}}(\mathbf{v}) = \frac{1}{2\pi\sqrt{\det \mathbf{R}}} e^{-\frac{1}{2}\mathbf{v}^T \mathbf{R}^{-1} \mathbf{v}} , \quad (6.25)$$

gdje $p_{\mathbf{w}}(\mathbf{v})$ predstavlja gustoću vjerojatnosti vektora mjernog šuma $\mathbf{W}(t)$ pri njegovoj vrijednosti \mathbf{v} . U tom slučaju statističke osobine mjernog šuma su na osnovu izraza (6.16) i (6.21) dane nultom srednjom vrijednošću i varijansom

$$M\{\mathbf{W}(t)\} = \overline{\mathbf{W}}(t) = \mathbf{0} , \quad V_{\mathbf{w}}(t, \tau) = M\{\mathbf{W}(t)\mathbf{W}^T(\tau)\} = \mathbf{R}(t)\delta(t - \tau) , \quad (6.26)$$

gdje elemente R_{ij} matrice \mathbf{R} za $i=j$ dobivamo izrazom (6.22) tako da ista poprima dijagonalnu formu (6.23). Ovdje je potrebno istaknuti da se pod pojmom mjernog »bijelog šuma« inherentno krije i statistička nezavisnost vektora $\mathbf{W}(t)$ sa vektorom stanja $\mathbf{X}(t)$ danog dinamičkog sustava (6.14), odnosno da vrijedi

$$V_{\mathbf{xw}}(t, \tau) = M\{[\mathbf{X}(t) - \overline{\mathbf{X}}(t)][\mathbf{W}(\tau)]^T\} = \mathbf{0} . \quad (6.27)$$



Slika 6.16 Dijagramski prikaz stacionarnog ergodičnog mjernog »bijelog šuma« čije amplitude posjeduju Gausovu razdiobu sa srednjom vrijednošću $\overline{w} = 0$ i varijansom $V_{\mathbf{w}} = 1$.

U slučaju stacionarnog ergodičnog mjernog »bijelog šuma« (slika 6.16) svi prethodni statistički pokazatelji koji vrijede za slučajni vektor vrijede i za bilo koji vremenski uzorak vektora mjernog šuma dobiven realizacijom stohastičkog procesa vođenjem mobilnog robota zadanom referentnom putanjom. Da bi se omogućilo praktično vođenje mobilnog robota na temelju prikupljenih informacija s njegovih izlaza i u realnijim uvjetima kontaminacije (zagađenosti) izlaza mjernim šumom potrebno je u pojedinim trenucima vremena izvršiti estimaciju (procjenu) vektora stanja $\mathbf{X}(t)$. U rješavanju postavljenog problema u literaturi je predloženo više rekurzivnih algoritama koji se oslanjaju na različite prilaze problemu estimacije kao što su leme ortogonalnosti između vektora pogreške estimacije $\mathbf{e}(t)$ i mjernog vektora izlaza $\tilde{\mathbf{y}}(t)$ ili vektora pogreške estimacije i vektora procijenjenog stanja $\hat{\mathbf{x}}(t)$ za koje općenito vrijedi

$$Kov\{\mathbf{e}(t), \tilde{\mathbf{y}}(t)\} = 0 \quad , \quad Kov\{\mathbf{e}(t), \hat{\mathbf{x}}(t)\} = 0 \quad , \quad (6.28)$$

zatim na metodama koje se baziraju na minimalnoj vrijednosti varijance estimacije i maksimalne vjerodostojnosti, rekurzivnoj metodi najmanjih kvadrata i Bayesov-oj metodi. Sve ove metode u sebi inherentno sadrže svojstva filtriranja signala. Procjena vektora stanja koji u sebi sadrži kompletnu informaciju o dinamičkom sustavu usko je povezana sa smanjenjem rasipanja (disperzije) vrijednosti vektora pogreške estimacije unutar određenog opsega vrijednosti, kako moguće vanjske i interne smetnje ne bi bitno utjecale na kvalitetu vođenja mobilnog robota zadanom referentnom trajektorijom. Taj postavljeni zahtjev ogleda se u minimizaciji traga varijancne matrice $\mathbf{H}(t)$ koja se definira kao

$$V_e(t, \tau) = Kov\{\mathbf{e}(t), \mathbf{e}(\tau)\} = M \left\{ [\mathbf{x}(t) - \hat{\mathbf{x}}(t)] [\mathbf{x}(\tau) - \hat{\mathbf{x}}(\tau)]^T \right\} = \mathbf{H}(t) \delta(t - \tau) \quad , \quad (6.29)$$

sa svojim komponentama

$$H_{ij} = M \left\{ [x_i(t) - \hat{x}_i(t)] [x_j(\tau) - \hat{x}_j(\tau)] \right\} \quad . \quad (6.30)$$

Općenito u literaturi filtriranje signala koja se u općenitom slučaju obavlja u vremenskom trenutku $\tau=t$ poznata je kao Vinerov problem a zasniva se na Viner-Hopfovoj jednadžbi [78, 79] koja se ogledno može dati u slijedećem obliku

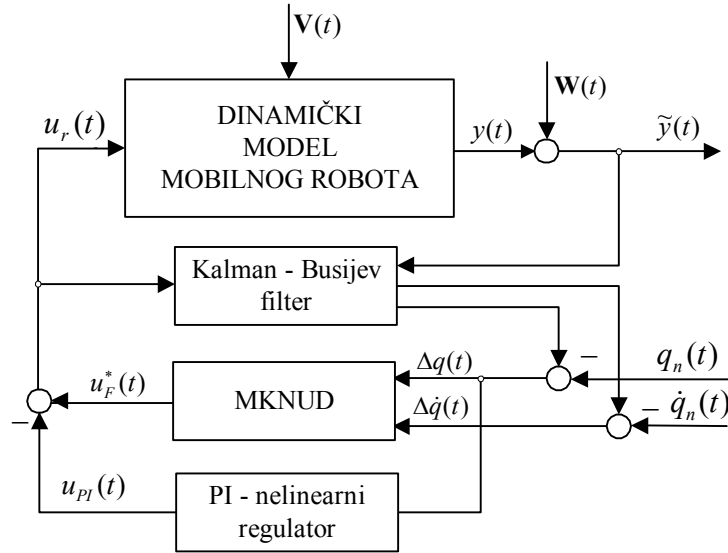
$$\mathbf{V}_{\hat{\mathbf{y}}\hat{\mathbf{y}}}(t, \theta) = \int_{t_0}^t \mathbf{G}_o(t, \tau) \mathbf{V}_{\hat{\mathbf{y}}\hat{\mathbf{y}}}(\tau, \theta) d\tau \quad , \quad t_0 < \theta < t \quad , \quad (6.31)$$

gdje $\mathbf{G}_o(t, \tau)$ predstavlja matricu impulsnih odziva filtera za estimaciju. Klasično rješenje Vinerovog problema ograničeno je na stacionarne stohastičke sustave sa smetnjom na beskonačnom vremenskom intervalu. Osim toga sustavi dobiveni takvim pristupom mogu narušavati princip kauzalnosti sustava, odnosno posjeduju mogućnost fizičke neostvarljivosti. Prethodno navedena ograničenja otklanjaju se primjenom **Kalman-Bucy-evog Filtera KBF-a**

(slika 6.17) za estimaciju vektora stanja u općim uvjetima djelovanja vanjskog šuma na ulazu sustava i internog šuma na izlazu polaznog dinamičkog sustava (6.14-15) u obliku [74]

$$\dot{\hat{\mathbf{X}}}(t) = (\mathbf{A} - \mathbf{K}_F \mathbf{C})\hat{\mathbf{X}}(t) + \mathbf{K}_F \tilde{\mathbf{Y}}(t) + (\mathbf{B} - \mathbf{K}_F \mathbf{D})\mathbf{U}_r(t) \quad , \quad \hat{\mathbf{X}}(t=0) = \hat{\mathbf{X}}(0) = \hat{\mathbf{X}}_0 \quad , \quad (6.32)$$

koja se još naziva i optimalni observer stanja.



Slika 6.17 Prikaz upravljačke strukture sa implementiranom **MKNUD** i nelinearnim **PI**-regulatorom sa Kalman-Bucijev filterom za procjenu vektora stanja u realnim uvjetima djelovanja smetnji pri **ON**-line vođenju mobilnog robota u realnom vremenu.

Ovdje je potrebno istaknuti da je transponirana matrica impulsnih odziva filtera za estimaciju u Viner-Hopfovoj integralnoj matricnoj jednadžbi (6.31) po strukturi potpuno jednaka Kalmanovom pojačanju **KBF**-a (6.32) i pritom vrijede slijedeći izrazi

$$\mathbf{K}_F = \mathbf{G}_0^T = \bar{\mathbf{H}}\mathbf{C}^T\mathbf{R}^{-1} \quad , \quad \mathbf{G}_0 = \mathbf{R}^{-1}\mathbf{C}\bar{\mathbf{H}} \quad , \quad (6.33)$$

gdje je $\bar{\mathbf{H}} = \bar{\mathbf{H}}^T \geq 0$ pozitivno semidefinitna simetrična matrica varijanci (6.29) koja se dobiva kao stacionarno rješenje nelinearne matricne diferencijalne Rikatijske jednadžbe [74], (prilog 8);

$$\dot{\mathbf{H}}(t) = \mathbf{E}\mathbf{H}(t) + \mathbf{H}(t)\mathbf{E}^T - \mathbf{H}(t)\mathbf{F}\mathbf{K}^T + \mathbf{G}\mathbf{Q}\mathbf{G}^T \quad , \quad \text{gdje je} \quad \mathbf{K}^T = \mathbf{R}^{-1}\mathbf{F}^T\mathbf{H}(t) \quad . \quad (6.34)$$

Ovako dani opći zapis ističe svojstvo dualnosti, budući da je za triplet matrica \mathbf{E} , \mathbf{F} i \mathbf{G} određen matricama dinamičkog modela (6.14-15)

$$\mathbf{E} = \mathbf{A} \quad , \quad \mathbf{F} = \mathbf{C}^T \quad \text{ i } \quad \mathbf{G} = \mathbf{B} \quad , \quad (6.35)$$

matricna Rikatijska diferencijalna jednadžba za dobivanje matrice varijance **KBF**-a, za odabrani triplet matrica

$$\mathbf{E} = \mathbf{A}^T \quad , \quad \mathbf{F} = \mathbf{B} \quad \text{ i } \quad \mathbf{G} = \mathbf{I} \quad , \quad (6.36)$$

ujedno i Rikatijska diferencijalna jednačica sa vremenom koji teče unazad (reverzivnim vremenom) u rješavanju zadatka optimalne regulacije. Stacionarnu matricu varijance $\bar{\mathbf{H}}$ **KBF**-a dobiva se uz dani triplet matrica (6.35) integracijom jednačice (6.34) s definiranim početnim uvjetima u obliku

$$\mathbf{H}(t_0) = \mathbf{H}_0 = M \left\{ [\mathbf{x}(t_0) - \hat{\mathbf{x}}(t_0)] [\mathbf{x}(t_0) - \hat{\mathbf{x}}(t_0)]^T \right\}, \text{ gdje je } \hat{\mathbf{x}}(t_0) = M \{ \mathbf{x}(t_0) \} = \bar{\mathbf{x}}_0, \quad (6.37)$$

iz kojeg proizlazi da se u početnom trenutku vremena varijanca pogreške estimacije zamjenjuje s varijancom vektora stanja. Za polazni dinamički sustav (6.14-15) pokazalo se je da vrijedi slijedeće: ako je matrični par \mathbf{A}, \mathbf{C} observabilan (mjerljiv), a matrični par \mathbf{A}, \mathbf{B} kontrolabilan (upravljiv) onda rješenje diferencijalne matrične Rikatijske jednačice za matricu varijance **KBF**-a $\mathbf{H}(t)$ pri bilo kojim odabranim početnim vrijednostima $\mathbf{H}_0 \geq 0$ nakon dovoljno proteklog vremena teži svojoj stacionarnoj vrijednosti $\bar{\mathbf{H}}$ [76]. Čak ako matrični par \mathbf{A}, \mathbf{C} nije potpuno mjerljiv a dinamički sustav (6.14-15) unatoč tome sadržava svojstvo detektibilnosti također se je pokazalo da vrijedi

$$\lim_{t \rightarrow \infty} \mathbf{H}(t) = \bar{\mathbf{H}}, \quad (6.38)$$

odnosno da optimalni observer ustaljenog stanja pri proizvoljno odabranim početnim uvjetima minimizira graničnu vrijednost (6.29)

$$\lim_{t \rightarrow \infty} M \{ \mathbf{e}(t) \mathbf{e}^T(t) \} = \text{tr}[\bar{\mathbf{H}}]. \quad (6.39)$$

Uz postojanje mjerne smetnje tipa »bijelog šuma« (slika 6.16) izlaza dinamičkog sustava (6.14-15) i odabrane varijancne matrice

$$\mathbf{Q} = \text{diag}[1 \quad 1], \quad \mathbf{R} = \text{diag}[1 \quad 1], \quad (6.40)$$


uz prethodno definirani triplet matrica (6.35) dobiva se integracijom nelinearne diferencijalne matrične Rikatijske jednačice (6.34) matrica varijance **KBF**-a (6.38) :

$$\bar{\mathbf{H}} = \begin{bmatrix} 0,2837 & -0,0004 & 0,0403 & -0,0001 \\ -0,0004 & 0,2837 & -0,0001 & 0,0403 \\ 0,0403 & -0,0001 & 0,19 & -0,01 \\ -0,0001 & 0,0403 & -0,01 & 0,19 \end{bmatrix}. \quad (6.41)$$

Pritom se je koristilo minimiziranje granične vrijednosti pogreške odnosno pogreške procjene ustaljenog stanja $\mathbf{e}(t) = \mathbf{x}(t) - \hat{\mathbf{x}}(t)$ koja je jednaka tragu matrice $\bar{\mathbf{H}}$ dim(4x4) (6.39). Do prethodno dobivene matrice varijance $\bar{\mathbf{H}}$ **KBF**-a ustaljenog stanja može se doći pri različito odabranim početnim uvjetima (6.37)

$$\mathbf{H}_{01} = \mathbf{0} \quad \mathbf{H}_{02} = \text{diag}[0,2] \quad \mathbf{H}_{03} = \text{diag}[0,5] \quad (6.42)$$

što je prikazano i dijagramima prijelazne pojave komponenata matrice $\bar{\mathbf{H}}$.



Slika 6.18 Dijagramski prikaz prijelazne pojave komponenta H_{ij} simetrične matrice varijance $\mathbf{H}(t)$ Kalman-Bucy filtera dobivene rješavanjem nelinearne diferencijalne matrice Rikatijske jednadžbe pri različitim početnim vrijednostima matrice \mathbf{H}_{0i} $i=1,2,3$ (6.42)


Na osnovu dobivene matrice varijance **KBF**-a (6.41), izrazom (6.33) izračunavaju se Kalmanova pojačanja koja iznose

$$\mathbf{K}_F^T = \begin{bmatrix} 0,2837 & -0,0004 & 0,0403 & -0,0001 \\ -0,0004 & 0,2837 & -0,0001 & 0,0403 \end{bmatrix}. \quad (6.43)$$

Prilikom simulacije vođenja mobilnog robota na digitalnom računalu u uvjetima postojanja interne mjerne smetnje, potrebno je stacionarnu mjernu smetnju tipa »bijelog šuma« srednje vrijednosti $\bar{w}_i = 0$ i varijance $V_{w_i} = \sigma_i^2$ koja postoji pri mjerenju pozicije u prostoru unutarnjih koordinata simulirati funkcijom $w_n(t)$. To je funkcija slučajnog odabira vrijednosti amplituda koje podliježu normalnoj Gausovoj razdiobi i predstavljaju bijeli šum nulte srednje vrijednosti i varijance jednake jedinici (slika 6.16). Stoga skalarnu komponentu mjerne smetnje $w_i(t)$ kao kontinuiranu funkciju vremena dobivamo izrazom

$$w_i(t) = \sqrt{V_{w_i}} w_n(t) = \sigma_i w_n(t). \quad (6.44)$$

Prilikom ON-line vođenja mobilnog robota zadanom referentnom trajektorijom (slika 3.8) uz upravljačku strukturu prikazanu na slici 6.17 i postojanja vektora mjerne smetnje tipa bijelog šuma nulte srednje vrijednosti i varijance 0,1 prikazana je na slici 6.19 jedna stohastička realizacija mjernog signala pozicije u prostoru unutarnjih upravljanih koordinata.



Slika 6.19 Stohastička realizacija mjernog signala pozicije lijevog i desnog pogonskog kotača pri ON-line vođenju mobilnog robota zadanom referentnom trajektorijom (slika 3.8) sa implementiranom upravljačkom strukturom prikazanom na (slici 6.17) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma parametara $\bar{w}_i = 0$ i $V_{w_i} = 0,1$.

Uvjetno rečeno matrice varijance \mathbf{R} i \mathbf{Q} dim(2x2) težinske su matrice u smislu pridruženih vrijednosti (težina) vanjskoj ili internoj smetnji. Ako komponente matrice \mathbf{Q} držimo konstantnih iznosa, onda će s elementima matrice \mathbf{R} u odnosu na već usvojene komponente matrice \mathbf{Q} biti određene težine u smislu pridavanja određenog stupnja filtracije mjernog šuma. Uz usvojene dijagonalne matrice \mathbf{Q} i \mathbf{R} većim omjerima \mathbf{R}/\mathbf{Q} posvećuje se veća pažnja filtriranju izlazne mjerne varijable sustava kontaminirane mjernim šumom, za razliku od manjih iznosa usvojenih komponenata matrice \mathbf{R} od elemenata matrice \mathbf{Q} pri čemu se onda više pažnje posvećuje filtriranju vanjske (pobuđujuće) smetnje. Posljedica većih omjera \mathbf{R}/\mathbf{Q} je pomicanje polova u negativnoj Gausovoj kompleksnoj poluravnini \mathbf{KBF} -a određenog karakterističnom jednadžbom


$$\det[\mathbf{sI} - \mathbf{A} + \mathbf{K}_f \mathbf{C}] = 0, \quad (6.45)$$

bliže imaginarnoj osi odnosno graničnom krugu polumjera $R=1$ »Z« ravnine, pri čemu \mathbf{KBF} poprima izrazito integralna svojstva. Dominantni polovi dinamičkog sustava (6.14-15) sa projektiranim \mathbf{KBF} -om (6.32) su polovi dobiveni karakterističnom jednadžbom (6.45). Odavde neposredno slijedi da većim iznosima Kalmanovih pojačanja (6.43) odgovaraju manji omjeri komponenata težinskih matrica \mathbf{R}/\mathbf{Q} [74]. Pri odabranim matricama dim(2x2)


$$\mathbf{Q} = \text{diag}[1], \quad \mathbf{R} = \text{diag}[0,125], \quad (6.46)$$

odnosno omjeru matrica $\mathbf{R}/\mathbf{Q}=1/8$ matrica Kalmanovih pojačanja iznosi

$$\mathbf{K}_F^T = \begin{bmatrix} 0,7623 & -0,0030 & 0,2908 & -0,0022 \\ -0,0030 & 0,7623 & -0,0022 & 0,2908 \end{bmatrix}. \quad (6.47)$$




Slika 6.20 Pogreška pozicije a) i brzine b) pri vođenju mobilnog robota trajektorijom, (slika 6.19) s Kalmanovim pojačanjima (6.43) upravljačke strukture (slika 6.17), u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$).




Slika 6.21 Promjena upravljačke varijable pri vođenju mobilnog robota trajektorijom, (slika 6.19) s Kalmanovim pojačanjima (6.43) upravljačke strukture (slika 6.17) u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$).

Uz nulte početne uvijete objekta regulacije (6.14) i **KBF**-a (6.32) na dijagramima (slika 6.20 i slika 6.22) prikazana je izlazna pogreška pozicije i brzine pri vođenju mobilnog robota zadanom trajektorijom (slika 3.8) sa različitim implementiranim vrijednostima Kalmanovih pojačanja (6.43) i (6.47) upravljačkog sustava prikazanog na (slici 6.17). Kako smanjivanje vrijednosti komponenata matrice \mathbf{R} (6.46), rezultira povećanim vrijednostima Kalmanovih pojačanja (6.47),

to je regulacijsko djelovanje dinamičkog sustava (6.14) u uvjetima postojanja samo interne smetnje tipa »bijelog šuma« smanjeno, što ima za posljedicu osim općenitog povećanja pogreške po poziciji i brzini i povećanje zašumljenosti korisnog signala.




Slika 6.22 Pogreška pozicije a) i brzine b) pri vođenju mobilnog robota trajektorijom, (slika 6.19) s Kalmanovim pojačanjima (6.47) upravljačke strukture (slika 6.17), u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)




slika 6.23 Promjena upravljačke varijable pri vođenju mobilnog robota trajektorijom, (slika 6.19) s Kalmanovim pojačanjima (6.47) upravljačke strukture (slika 6.17) u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$)

Kako je općenito fluktuacija pogreške po poziciji i brzini povećana to se pred upravljačkim sustavom u takvim uvjetima rada postavljaju povećani zahtjevi u pogledu upravljačke varijable

$u_r(t)$ (slika 6.23). Uz filtriranje izlazne mjerne varijable $\tilde{y}(t)$ (6.15), kao osnovnog zadatka **KBF**-a javlja se i zadatak estimacije odnosno procjene stanja vođenog objekta danog dinamičkim sustavom (6.14). Ocjena uspješnosti filtriranja izlazne mjerne varijable pozicije $\tilde{y}(t)$, odnosno ocjena uspješnosti estimacije izlazne varijable $y(t)$ dana je kroz varijancu pogreške između izlazne $y(t)$ i estimirane varijable $\hat{y}(t)$ stanja pozicije dinamičkog sustava (6.14). Pri implementiranim Kalmanovim pojačanjima (6.43) varijanca mjernog šuma izlazne varijable pozicije (slika 6.24a) iznosi $9,72 \cdot 10^{-5}$, dok sa odabranim težinskim matricama (6.46) odnosno Kalmanovim pojačanjima (6.47) varijanca mjernog šuma povećala se je približno tri puta što se može vidjeti dijagramima pogreške estimacije izlazne varijable pozicije (slika 6.25a). Povećanje varijance pogreške procjene stanja pozicije, popraćeno je odgovarajućim povećanjem varijance pogreške procjene stanja brzine, kao što je prikazano dijagramima na (slici 6.24b i 6.25b). Uslijed povećanja Kalmanovih pojačanja (6.47), maksimalne vrijednosti pogreške uslijed procjene stanja pozicije i brzine približno se povećavaju dva odnosno osam puta.



Slika 6.24 Dijagrami pogreške estimacije izlazne varijable pozicije a) i stanja brzine b), pri vođenju mobilnog robota trajektorijom (slika 6.19) i implementiranim Kalmanovim pojačanjima (6.43) dane upravljačke strukture (slika 6.17) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$).




Slika 6.25 Dijagrami pogreške estimacije izlazne varijable pozicije a) i stanja brzine b), pri vođenju mobilnog robota trajektorijom (slika 6.19) sa implementiranim Kalmanovim pojačanjima (6.47) dane upravljačke strukture (slika 6.17) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$).

Pokazalo se je da **KBF** osim filtriranja izlazne mjerne varijable sustava ima i funkciju da na osnovu trenutno izmjerenih ulaza i izlaza dinamičkog sustava vrši estimaciju stanja objekta regulacije. Zato se sa pravom još naziva i optimalni observer stanja. U dinamičkom sustavu sa vremenski invarijantnim matricama **A**, **B** i **C** najčešće se koristi optimalni observer ustaljenog stanja koji je vremenski stacionaran. **KBF** pridružen objektu regulacije optimalni je observer stanja zadanog objekta u tom smislu što za prethodno odabrane vrijednosti komponenata matrica varijance **Q** i **R** i Kalmanovog pojačanja izračunatog rješavanjem nelinearne diferencijalne matrične Rikatijske jednadžbe granična vrijednost dana izrazom (6.39) dostiže minimum. Radi boljeg uvida u prilike postupka procijene varijabli stanja zadanog dinamičkog sustava u nastavku se **KBF** promatra samo kao optimalni observer stanja s osnovnim zadatkom da se na osnovu mjerenja ulaza i izlaza dinamičkog sustava uspješno izvrši estimacija varijabli stanja objekta regulacije. Za jednake početne uvijete objekta regulacije i optimalnog observera stanja odziv sustava praktično se ne razlikuje od odziva objekta regulacije bez observera. Dakle za međusobno bliske početne uvijete procijenjena vrijednost izlaza sustava $\hat{y}(t)$ približno je jednaka izlazu objekta regulacije $y(t)$, te je pogreška procijene $e(t) = y(t) - \hat{y}(t)$ relativno malena da bi bilo kako odabrani iznosi Kalmanovih pojačanja imali značajan utjecaj. U tom slučaju stanje observera $x_i(t)$ $i=1,2,\dots,4$ u pojedinim trenucima vremena prvenstveno ovise o

ulaznim vodećim referentnim veličinama. Ako u početnom trenutku vremena objekt regulacije ima vrijednosti stanja koja značajno odstupaju od stanja observera (slika 6.26) pogreška estimacije će biti značajna, te u svrhu njezinog brzog vremenskog iščezavanja, potrebno je imati Kalmanova pojačanja velikih iznosa. U zadatku filtracije izlazne varijable kontaminirane mjernom smetnjom to je jedino moguće pri vrlo malim odabranim vrijednostima komponenata matrice varijance \mathbf{R} . Na slici 6.26 za odabrana početna stanja objekta regulacije i observera

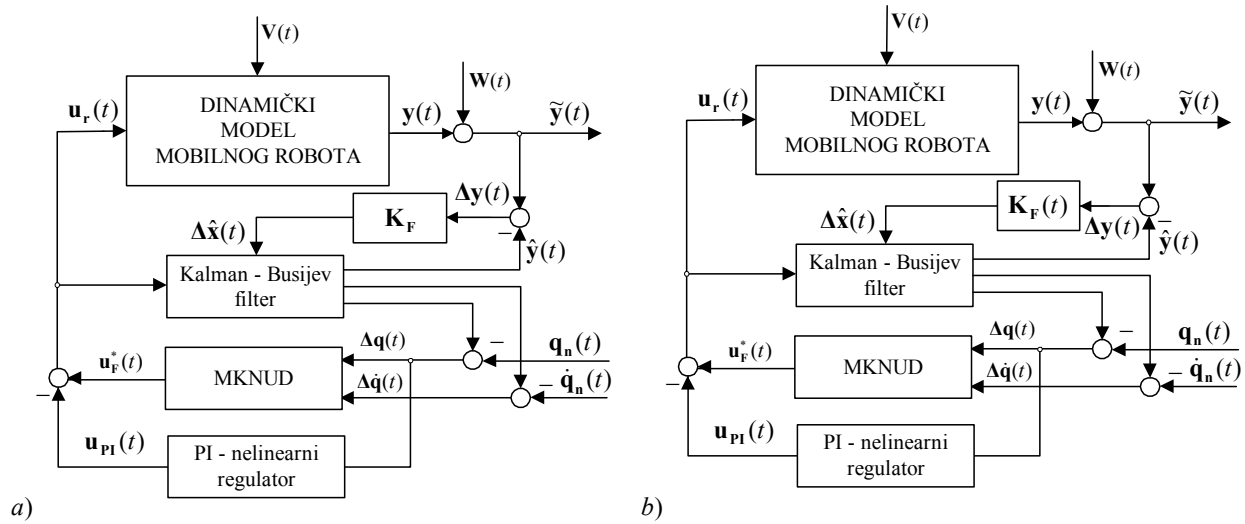
$$\mathbf{X}_0 = [0,045 \quad -0,045 \quad 0 \quad 0] , \quad \hat{\mathbf{X}}_0 = [0 \quad 0 \quad 0 \quad 0] , \quad (6.48)$$

te odabrane težinske matrice dane izrazom (6.40 i 6.46), dani su dijagramski prikazi prijelazne pojave pogreške estimacije kod kojih je posve evidentno da pri manjim omjerima komponenata težinskih matrica \mathbf{R}/\mathbf{Q} , odnosno većim vrijednostima Kalmanovih pojačanja daleko je brža procjena stanja sustava odnosno izlazne varijable objekta regulacije.



Slika 6.26 Dijagrami iščezavanja pogreške procijene izlazne varijable pozicije servosustava lijevog a) i desnog b) pogonskog kotača pri vođenju mobilnog robota trajektorijom (slika 3.8), uz početne uvijete (6.48) upravljačke strukture (slika 6.27a), i Kalmanova pojačanja (6.43) \Rightarrow (—); (6.47) \Rightarrow (---) i vremenski promjenjivih neizrazitih pojačanja $\mathbf{K}_F(e,t) \Rightarrow$ (- · -) upravljačke strukture na (slici 6.27b).

Izborom velikih vrijednosti Kalmanovih pojačanja, polovi karakteristične jednadžbe (6.45) više se udaljavaju nalijevo od imaginarne osi negativne S-poluravnine, odnosno približavaju ishodištu (Z) ravnine, gdje se pritom izražavaju diferencijalna svojstva optimalnog observera stanja. Odabir Kalmanovih pojačanja u **KBF**-u prvenstveno je uvjetovan postojanjem vanjske ili interne smetnje koja je obično visoke frekvencije. Prema tome je evidentno da tako izabrane velike vrijednosti Kalmanovih pojačanja dovode do znatno većeg pojačanja mjerne smetnje od mjerenog korisnog signala što dovodi do smanjenja kvalitete procijene, odnosno do povećane fluktuacije procijenjenog stanja $\hat{x}(t)$ oko stvarnog stanja $x(t)$ **OR**, što je prikazano i na dijagramima na slici 6.24 i 6.25.



Slika 6.27 Upravljačka struktura s implementiranom **MKNUD** i nelinearnim **PI**-regulatorom sa Kalman-Bucy filterom kao optimalnim observerom ustaljenog stanja sa stacionarnim vrijednostima K_F a), i nelinearnim vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $K_F(\Delta y, t)$ pri **ON-line** vođenju mobilnog robota u uvjetima postojanja vanjske i interne smetnje.

U svrhu otklanjanja navedenih nedostataka vremenski invarijantna Kalmanova pojačanja zamjenjuju se nelinearnim vremenski varijabilnim neizrazitim vrijednostima (slika 6.27b) uz zadržavanje povećanog stupnja suboptimalnosti **KBF**-a. U tom slučaju struktura matrice Kalmanovih pojačanja (6.43 i 6.47) djeluje kao neizraziti adaptacijski mehanizam [67] i zamjenjuje se sa suboptimalnom strukturom slijedećeg oblika

$$K_F^T(\Delta y, t) = \begin{bmatrix} Y_{x_{11}}(\Delta y_1, t) & 0 & Y_{x_{31}}(\Delta y_1, t) & 0 \\ 0 & Y_{x_{22}}(\Delta y_2, t) & 0 & Y_{x_{42}}(\Delta y_2, t) \end{bmatrix}, \quad (6.49)$$

čije komponente predstavljaju normalizirane vrijednosti položaja centara izlaznih neizrazitih skupova

$$Y_{x_{ij}}(\Delta y_j) = \frac{F_j}{(\Delta y_j) \beta_{ij}} (1 + |\Delta y_j|^{\alpha_j}) (1 - \frac{\omega_j(\Delta y_j)}{p_i}) \text{sgn}(\Delta y_j). \quad (6.50)$$

Ovisno u kojem opsegu vrijednosti se nalazi pogreška procijene izlaza dinamičkog sustava Δy_j kao ulazne varijable neizrazitog skupa, definira se aktivacijska funkcija $\omega_j(\Delta y_j)$

$$\text{za } -1 \leq \Delta y_j \leq x_{ai}^j \Rightarrow \omega_j(\Delta y_j) = \frac{1}{2} \sum_{k=1}^{p_j} \frac{1}{\exp(\beta_{ij} \varepsilon_k^j |\Delta y_j|)} (1 - \cos \frac{\pi \cdot (\Delta y_j - x_{ck}^j + T_k^j / 2)}{T_{1k}^j}), \quad (6.51)$$

$$\text{za } \underline{x}_{ai}^j \leq \Delta y_j \leq \underline{x}_{bi}^j \Rightarrow \omega_j(\Delta y_j) = \sum_{k=1}^{p_j} \frac{1}{\exp(\beta_{ij} \varepsilon_k^j |\Delta y_j|)} , \quad (6.52)$$

$$\text{za } \underline{x}_{bi}^j \leq \Delta y_j \leq 1 \Rightarrow \omega_j(\Delta y_j) = \frac{1}{2} \sum_{k=1}^{p_j} \frac{1}{\exp(\beta_{ij} \varepsilon_k^j |\Delta y_j|)} \left(1 - \cos \frac{\pi \cdot (\underline{x}_{ck}^j + T_k^j / 2 - \Delta y_j)}{T_{1k}^j}\right) , \quad (6.53)$$

gdje su granice opsega vrijednosti definirane izrazima (2.5), dok β_{ij} predstavlja vremenski promjenjivu varijablu raščlanjenosti i-tog stanja neizrazitih skupova j-te ulazne varijable koja se dobiva iskustvenim izrazom

$$\beta_{ij}(\Delta y_j, t) = \kappa_{1i} + \kappa_{2i} |\Delta y_j(t) / K_{\Delta y_j}| . \quad (6.54)$$

Pritom su κ_{1i} , κ_{2i} iskustveni faktori, a $K_{\Delta y_j}$ označava koeficijent normiranja ulazne varijable Δy_j . **KBF** oblika (6.32) zapisujemo u nešto izmijenjenom obliku

$$\dot{\hat{\mathbf{X}}}(t) = \mathbf{A}\hat{\mathbf{X}}(t) + \mathbf{K}_F \Delta \mathbf{Y}(t) + (\mathbf{B} - \mathbf{K}_F \mathbf{D}) \mathbf{U}_r(t) , \quad \hat{\mathbf{X}}(t=0) = \hat{\mathbf{X}}(0) = \hat{\mathbf{X}}_0 , \quad (6.55)$$

pri čemu je pogreška procijene vektora izlaza $\Delta \mathbf{Y} = [\Delta y_1 \quad \Delta y_2]^T$ definirana kao

$$\Delta \mathbf{Y}(t) = \tilde{\mathbf{Y}}(t) - \hat{\mathbf{Y}}(t) = \tilde{\mathbf{Y}}(t) - \mathbf{C}\hat{\mathbf{X}}(t) . \quad (6.56)$$

Sa novo uvedenim nelinearnim vremenski varijabilnim neizrazitim vrijednostima pojačanja (6.49) predložena je na osnovu izraza (6.49) i (6.55) nova struktura **KBF**-a (slika 6.27b) u slijedećem obliku

$$\dot{\hat{\mathbf{X}}}(t) = \mathbf{A}\hat{\mathbf{X}}(t) + \Delta \hat{\mathbf{X}}(\Delta \mathbf{Y}, t) + (\mathbf{B} - \mathbf{K}_F \mathbf{D}) \mathbf{U}_r(t) , \quad \hat{\mathbf{X}}(t=0) = \hat{\mathbf{X}}(0) = \hat{\mathbf{X}}_0 . \quad (6.57)$$

Ovdje se prirast vektora procijene stanja sustava na osnovu izraza (6.49-54) i pogreške procijene izlazne varijable sustava dobiva matričnom funkcijom u obliku

$$\Delta \hat{\mathbf{X}}(\Delta \mathbf{Y}, t) = \mathbf{K}_F(\Delta \mathbf{Y}, t) \Delta \mathbf{Y} . \quad (6.58)$$

Ulazni neizraziti skupovi definiranih komponenata pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ imaju iste parametre kao već definirani ulazni neizraziti skupovi neizrazitog analitičkog regulatora dani tablicom 2.1, dok su ostali parametri od značaja dani slijedećom tablicom:


Parametri	1. SSG robota (rotacija)	2. SSG robota (rotacija)
F_1, F_2	0,012	0,012
α_1, α_2	0	0
$\kappa_{11}, \kappa_{21}, \kappa_{12}, \kappa_{22}$	0,5	196,4
$\kappa_{13}, \kappa_{23}, \kappa_{14}, \kappa_{24}$	60	145
$K_{\Delta y_1}, K_{\Delta y_2}$	4	4

Tablica 6.1 Osnovni parametri neizrazitog pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$

Upravo zbog neizrazitog karaktera implementiranih vremenski varijabilnih nelinearnih pojačanja definiranim izrazom (6.49), brzina iščezavanja pogreške procjene izlazne varijable sustava veća je nego uz odabrane konstantne vrijednosti Kalmanovih pojačanja, što se vidi i na dijagramima prikazanim na slici 6.26. Uz definirani položaj centara izlaznih neizrazitih skupova jednadžbom (6.50) i odabrane parametre dane tablicom 6.1 osiguran je regresivni mod rada neizrazitih vrijednosti pojačanja. To općenito znači da prirast ulazne pogreške dovodi do negativnog prirasta položaja centra neizrazitog skupa, što je nasuprot progresivnom modu rada projektiranog neizrazitog analitičkog regulatora u glavnoj grani sustava. U tom slučaju nultoj ulaznoj pogreški odgovara maksimalna vrijednost položaja centra izlaznog neizrazitog skupa, dok je sa nultim položajem centra izlaznog neizrazitog skupa definirana maksimalna normalizirana vrijednost ulazne pogreške. Ako se prilikom vođenja mobilnog robota zadanom referentnom trajektorijom (slika 3.8) u prostoru unutarnjih koordinata, ograničimo na postojanje mjerne stacionarne smetnje tipa »bijelog šuma« srednje vrijednosti $\bar{w}_i = 0$ i maksimalne varijance $V_{w_i} = 0,1$, onda parametre neizrazitih vrijednosti pojačanja (tablica 6.1), odabiremo tako da položaji centara izlaznih neizrazitih skupova uz općenito zadovoljenu nejednadžbu $Y_x(\Delta \underline{y}_j, t) \leq 2$ zadovoljavaju i slijedeće pretpostavke:


$$M\{Y_{x_{11}}(\Delta \underline{y}_1, t)\} = M\{Y_{x_{22}}(\Delta \underline{y}_2, t)\} = 0,2837, \quad M\{Y_{x_{31}}(\Delta \underline{y}_1, t)\} = M\{Y_{x_{42}}(\Delta \underline{y}_2, t)\} = 0,0403, \quad (6.59)$$

koji govore da je srednja očekivana vrijednost položaja centara izlaznih neizrazitih skupova neizrazitih pojačanja (6.49) jednaka ustaljenim vrijednostima Kalmanovih pojačanja (6.43) dobivenih rješavanjem nelinearne Rikatijske matrične jednadžbe (6.34-35) pri početno odabranim matricama varijance (6.40). Osim statičke nelinearnosti osigurane regresivnom modom rada neizrazitih vrijednosti pojačanja (6.49-50), izrazom (6.54) definira se i dinamička nelinearnost koja je uvjetovana promjenjivom raščlanjenošću ulaznih neizrazitih skupova.




Slika 6.28 Dijagrami pogreške pozicije a) i brzine b) pri vođenju mobilnog robota trajektorijom (slika 3.8) s implementiranim nelinearnim vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ upravljačke strukture (slika 6.27b) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma ($\bar{\mathbf{w}}_i = 0$, $V_{\mathbf{w}_i} = 0,1$).

Kod većih ulaznih vrijednosti pogreške procijene izlazne j -te varijable sustava, veća je i vrijednost varijable β_j što dodatno doprinosi smanjenju prirasta položaja centra neizrazitog skupa. Primjena neizrazitih vrijednosti Kalmanovih pojačanja osim u povećanju brzine procjene stanja sustava ogleda se i u boljim karakteristikama prilikom filtriranja izlazne mjerne varijable u uvjetima postojanja stacionarne mjerne smetnje tipa »bijelog šuma« (slika 6.16).



Slika 6.29 Dijagram upravljačke varijable pri vođenju mobilnog robota trajektorijom, (Slika 6.19) s implementiranim nelinearnim vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ upravljačke strukture (slika 6.27b) u uvjetima postojanja izlazne mjerne smetnje tipa bijelog šuma ($\bar{\mathbf{w}}_i = 0$, $V_{\mathbf{w}_i} = 0,1$).


Filtrirajuće djelovanje povećava se približno pet puta u odnosu na implementirana vremenski invarijantna Kalmanova pojačanja, što se osim smanjenja fluktuacije pogreške pozicije i brzine (slika 6.28) očituje i u smanjenju fluktuacije upravljačke veličine (slika 6.29) te procijenjenih vrijednosti oko stanja objekta regulacije što slijedi neposredno i iz prikazanih dijagrama pogreške procijenjenih stanja sustava (slika 6.30).



Slika 6.30 *Dijagrami pogreške estimacije izlazne varijable pozicije a) i stanja brzine b), pri vođenju mobilnog robota trajektorijom (slika 3.8) s vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ strukture (slika 6.27b), u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{\mathbf{w}}_i = 0$, $V_{\mathbf{w}_i} = 0,1$)*


Implementirane neizrazite vrijednosti Kalmanovih pojačanja ekvivalentne su neizrazitim vrijednostima komponenata matrice varijanci \mathbf{Q} i \mathbf{R} pri ustaljenim (stacionarnim) vrijednostima Kalmanovih pojačanja \mathbf{K}_F . Većim iznosima ulazne pogreške procijene stanja izlazne varijable sustava odgovaraju manji iznosi neizrazitih vrijednosti Kalmanovih pojačanja, što je pri stacionarnim vrijednostima Kalmanovih pojačanja ekvivalentno povećanim iznosima neizrazitih vrijednosti komponenata matrice \mathbf{R} . To znači da se u vremenskom trenutku povećanih iznosa ulazne pogreške pridružuje veća težinska vrijednost mjernoj smetnji jer je varijanca ulazne varijable u tom vremenskom trenutku veća. Pri manjim vrijednostima varijance ulazne pogreške procijene stanja izlazne varijable sustava pridružuje se manje vrijednosti težina matrice \mathbf{R} , što znači da su u tom vremenskom trenutku posvećuje veća pažnja vanjskoj smetnji, gdje se uslijed povećanih iznosa neizrazitih Kalmanovih pojačanja povećava brzina procijene stanja sustava. Predloženom jednokoračnom metodom učinjen je kompromis između dva međusobno

kontradiktorna zahtjeva brzine iščezavanja pogreške procijene stanja sustava i smanjenja utjecaja internih i vanjskih smetnji. Dijagramima na (slici 6.31) dane su vremenske promjene neizrazitih vrijednosti pojačanja (6.49) ovisnih o pogreški procjene stanja izlazne varijable sustava prilikom vođenja mobilnog robota referentnom putanjom (slika 3.8) u uvjetima postojanja mjerne smetnje tipa »bijelog šuma« nulte srednje vrijednosti i varijance $V_{w_i} = 0,1$.



Slika 6.31 *Dijagrami neizrazitih vrijednosti Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ (6.49) upravljačke strukture (slika 6.27b) pri vođenju mobilnog robota trajektorijom (slika 6.19), u uvjetima postojanja mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0,1$).*

Dinamička nelinearnost uvjetovana je promjenjivim vrijednostima varijabli β_{ij} raščlanjenosti i-tog stanja neizrazitih skupova j-te ulazne varijable pogreške procjene stanja prema izrazu (6.54) i danim parametrima u (tablica 6.1). Dijagramima na slici 6.32 prikazana je promjena parametra β_{ij} raščlanjenosti ulaznih neizrazitih skupova prilikom vođenja mobilnog robota zadanom referentnom putanjom (slika 3.8).



Slika 6.32 Promjena parametra β_{ij} raščlanjenosti i -tog stanja neizrazitih skupova j -te ulazne varijable (6.54), s neizrazitim vrijednostima Kalmanovih pojačanja (6.49) upravljačke strukture (slika 6.27b) pri vođenju mobilnog robota trajektorijom, (slika 3.8) u uvjetima prisutne mjerne smetnje tipa bijelog šuma ($\bar{w}_i = 0$, $V_{w_i} = 0, 1$).

6.4 ON-line vođenje mobilnog robota u realnom vremenu uz djelovanje nestacionarnog poremećaja tipa »bijelog šuma«

Dobre karakteristike neizrazitih vrijednosti Kalmanovih pojačanja prvenstveno dolaze do izražaja pri vođenju objekta regulacije u uvjetima postojanja nestacionarne mjerne smetnje. U svrhu simulacije, stohastička realizacija nestacionarne mjerne smetnje dana je u vremenskoj funkciji slučajnog odabira vrijednosti amplituda $w_n(t)$, odnosno u općenitoj vremenskoj funkciji stacionarne mjerne smetnje tipa »bijelog šuma« nulte srednje vrijednosti i varijance V_{w_i} (6.44)

$$\tilde{w}_i(t) = \sqrt{V_{w_i}} \sin(0,92(t - 10,74))(t - 10,74)w_n(t) , \quad (6.60)$$


gdje $\tilde{w}_i(t)$ predstavlja komponentu nestacionarne mjerne smetnje i -te izlazne mjerne varijable sustava. Ako slučajni odabir vrijednosti amplituda podliježe Gausovoj normalnoj raspodjeli nulte srednje vrijednosti i jediničnoj varijanci, gustoća vjerojatnosti se daje u obliku [78]

$$p_w(v) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}v^2} , \quad (6.61)$$

dok se gustoća vjerojatnosti nestacionarne mjerne smetnje dane izrazom (6.60) dobiva prema [78] u obliku


$$p_{\tilde{w}(t)}(v, t) = \frac{1}{\sqrt{V_{w_i}} |\sin(0,92(t - 10,74))(t - 10,74)| \sqrt{2\pi}} e^{-\frac{1}{2V_{w_i} \sin^2(0,92(t - 10,74))(t - 10,74)^2} v^2} , \quad (6.62)$$

što govori da je gustoća vjerojatnosti kod nestacionarnog mjernog šuma vremenski varijabilna funkcija. Prema izrazu (6.60) dijagramom na slici 6.33, prikazana je jedna stohastička realizacija po normaliziranim vremenski diskretnim koracima (n) nestacionarnog mjernog šuma parametra $V_{w_i}=0,1$.



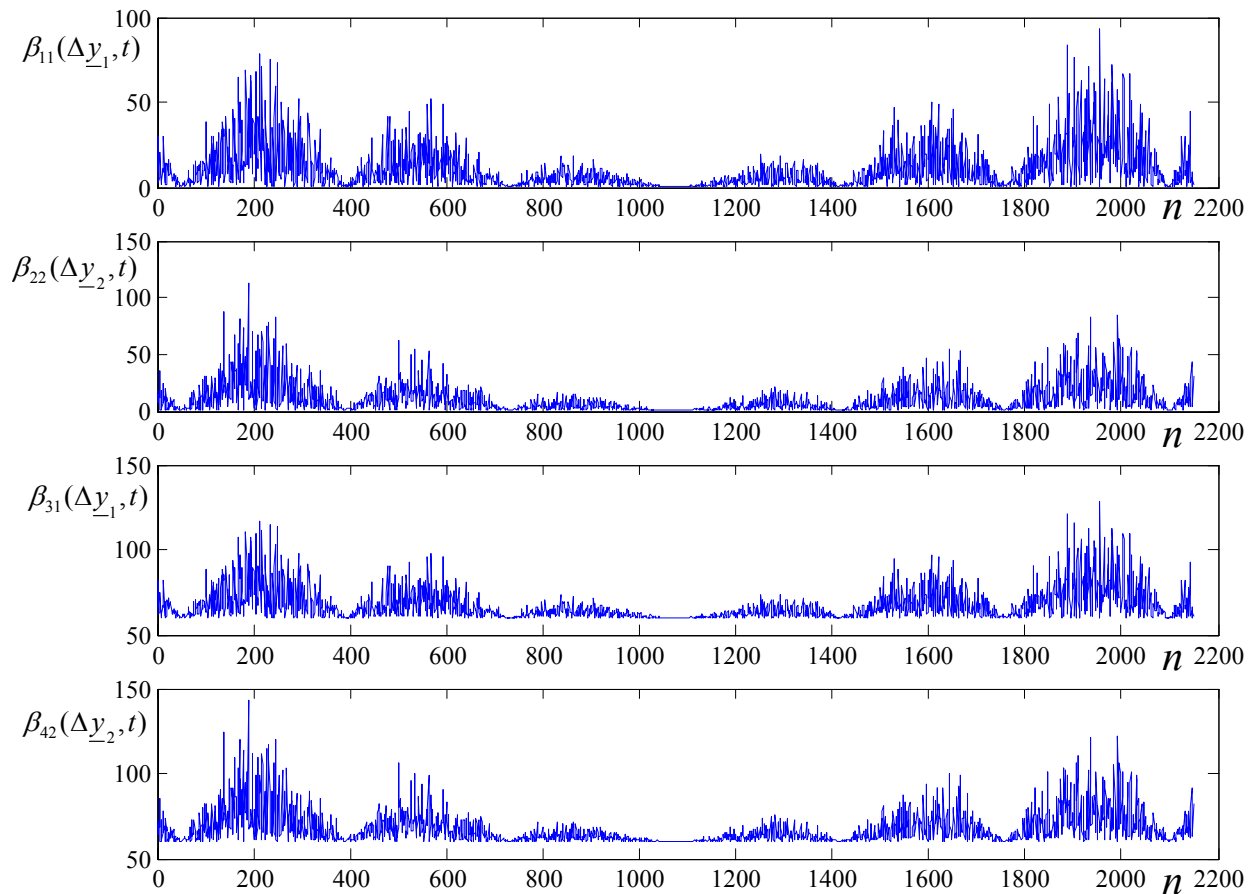
Slika 6.33 Dijagram nestacionarnog mjernog »bijelog šuma« nulte srednje vrijednosti (6.60).

Filtrirajuće djelovanje pri vođenju mobilnog robota zadanom referentnom trajektorijom u uvjetima nestacionarne mjerne smetnje (6.60) sa implementiranim neizrazitim vrijednostima Kalmanovih pojačanja (6.49-6.54) upravljačke strukture (slika 6.27b) približno je deset puta veće nego s vremenski invarijantnim pojačanjima (6.43). Daleko bolja svojstva u smislu kompromisa između brzine procijene stanja objekta regulacije i filtrirajućeg djelovanja dolaze do izražaja pri vremenski invarijantnoj matrici \mathbf{Q} i promjenjivim vrijednostima komponenata težinske matrice \mathbf{R} , odnosno promjenjivim vrijednostima Kalmanovih pojačanja (6.49). Pogreška procijene stanja sustava pri normaliziranim vremenski diskretnim koracima (n) prikazana je dijagramima na slici 6.34.




Slika 6.34 Pogreška estimacije izlazne varijable pozicije a) i stanja brzine b) pri vođenju mobilnog robota trajektorijom (slika 6.19) sa vremenski varijabilnim neizrazitim vrijednostima Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ upravljačke strukture (slika 6.27b) u uvjetima postojanja nestacionarne mjerne smetnje (izraz 6.60 i slika 6.33).

Vremenski promjenjive vrijednosti β_{ij} faktora raščlanjenosti i-tog stanja neizrazitih skupova j -te ulazne varijable (6.54) dodatno doprinose nelinearnosti ovisno o dinamici pogreške procijene izlazne varijable sustava. Povećana vrijednost pogreške procijene izlazne varijable sustava dovodi do povećanih vrijednosti faktora raščlanjenosti β_{ij} što je prikazano dijagramima na (slici 6.35).



Slika 6.35 Promjena varijable β_{ij} raščlanjenosti i -tog stanja neizrazitih skupova j -te ulazne varijable (6.54), sa neizrazitim vrijednostima Kalmanovih pojačanja (6.49), strukture (slika 6.27b) pri vođenju mobilnog robota trajektorijom (slika 6.19) pri postojanju nestacionarne mjerne smetnje (izraz 6.60 i slika 6.33).

Osim smanjenja faktora raščlanjenosti β_{ij} , sa smanjenjem pogreške procjene pozicije kao izlazne varijable sustava povećavaju se i vrijednosti položaja centara izlaznih neizrazitih skupova koji u ovom slučaju odgovaraju komponentama neizrazitih vrijednosti Kalmanovih pojačanja danih izrazom (6.49). U uvjetima stohastičke smetnje smanjenje pogreške procijene izlazne varijable sustava dovodi do povećanja neizrazitih vrijednosti Kalmanovih pojačanja, iz čega neposredno slijedi da su veće vrijednosti težina pridružene vanjskoj slučajnoj smetnji odnosno više se pažnje posvećuje brzini estimacije stanja sustava nego filtriranju izlazne mjerne varijable sustava. U uvjetima interne smetnje nestacionarnog tipa (6.60) dijagramima na (Slici 6.36) prikazane su po normaliziranim vremenski diskretnim koracima (n) komponente neizrazitih vrijednosti pojačanja (6.49) kao položaji centara izlaznih neizrazitih skupova u funkciji pogreške procijene izlazne varijable sustava.



Slika 6.36 Promjena neizrazitih vrijednosti Kalmanovih pojačanja $\mathbf{K}_F(\Delta \mathbf{y}, t)$ (6.49) upravljačke strukture (slika 6.27b) pri vođenju mobilnog robota trajektorijom (slika 6.19), u uvjetima postojanja nestacionarne mjerne smetnje (izraz 6.60 i slika 6.33).

7. GLAVNI REZULTATI RADA

Razradom po poglavljima postavljenog zadatka na osnovi hipoteze ove doktorske disertacije (podpoglavlje 1.5) došlo se je do slijedećih glavnih rezultata rada:

Uvođenjem novih analitičkih oblika funkcije pripadnosti ulaznim neizrazitim skupovima, kao i stupnjevane aktivacijske funkcije sa stupnjevanom pripadnošću ulazne varijable i-tom neizrazitom skupu poboljšana je proces inferencije (odlučivanja). To neposredno slijedi iz povećanja karakteristične površine čime je postignuta veća iskoristivost raspoloživog karakterističnog područja djelovanja **NAR**-a. Stoga novi predloženi suvremeni analitički pristup neizrazitoj regulaciji u potpunosti opravdava već prije uvedeni postulat koji sada postaje geslo poboljšanog analitičkog pristupa neizrazitoj regulaciji, a to je da »Dovoljan broj slobodnih parametara neizrazitog regulatora može aproksimirati bilo koju analitičku funkciju« [32, 85].

Provedena je detaljna analiza utjecaja slobodnih parametara u faznoj ravnini stanja na neizrazito djelovanje **PNAR**-a. Definiranjem stupnja neizrazitog djelovanja, ističu se dva osnovna moda rada **NAR**-a. U teorijskom smislu to doprinosi podjeli i razvoju **PNAR**-a u dva pravca. Uvođenjem pojma progresivnog moda rada definira se prva, a degresivnim modom rada druga klasa neizrazitog analitičkog regulatora, čime se direktno dovodi u vezu djelovanje **PNAR**-a sa asimptotskom i eksponencijalnom stabilnosti sustava.

Dovođenjem u vezu sa nultim stupnjem neizrazitog djelovanja predložen je postupak početnog podešavanja **PNAR**-a, gdje se nakon ugađanja **PNAR**-a pokazalo da on dosta dobro emulira klasični linearni **PD** i/ili **PI**-zakon upravljanja o čemu govore i rezultati simulacije vođenja **AMR**-a zadanom nominalnom putanjom.

S obzirom na pogrešku slijeđenja zadane nominalne trajektorije, u **OFF**-line modu rada predložen je algoritam obučavanja **PNAR**-a, koji rezultira uspješnim adaptiranjem slobodnih F i β parametara. Predloženi nelinearni algoritam adaptacije temelji se na modificiranoj gradijentnoj metodi u sklopu koje se postavljaju ograničenja na koeficijente obučavanja s obzirom na brzinu konvergencije i stabilnost algoritma adaptacije. Vođenjem **AMR** složenijom nominalnom trajektorijom pri različitim kutovima skretanja adaptirani (obučeni) **PNAR** pokazao je dosta dobre rezultate u usporedbi sa klasičnim zakonom upravljanja o čemu govore i priloženi rezultati simulacije u vidu dijagrama.

Pokazana je realizacija **PNAR**-a kao nelinearnog diskretnog **PD** i **PI** regulatora, te su paralelnim dodavanjem integracijskog člana izlazu **PD-PNAR**-a i izlaznoj upravljanoj varijabli uspješno realizirane nelinearne strukture **PID** regulatora, u sklopu kojih je predložen i algoritam podešavanja integralnog pojačanja. Na temelju svega iznesenog, na kraju su prikazane strukture samoorganiziranja **PNAR**-a.

Da bi se omogućilo **ON**-line vođenje **AMR**-a u realnom vremenu uvedena je **MKNUD**-a. U uvjetima stacionarne i/ili nestacionarne mjerne smetnje uveden je i mehanizam neizrazitih promjena Kalmanovih pojačanja. Prema predloženom neizrazitom adaptacijskom algoritmu ovisno o mjerenim vrijednostima pogreške pozicije, u toku **ON**-line vođenja mobilnog robota, mijenjaju se vrijednosti slobodnog β parametra i elementi Kalmanovih pojačanja po normaliziranim vremenski diskretnim koracima (n). Uvođenjem **MKNUD**-a stvorena je diskretna baza podataka za daljnju primjenu sofisticiranijih algoritama upravljanja kao što su umjetne neuronske mreže i genetski algoritmi koji zajedno sa neizrazitim upravljanjem tvore hibridne zakone upravljanja kao što je npr. neuro-fazi upravljanje. Time se otvara daljnji mogući smjer nastavka rada, koji uključuje i komparativne studije pristupa sinteze **PNAR**-a s drugim algoritmima u različitim primjenama [81, 82]. U budućem djelovanju moguća je i verifikacija predloženih algoritama upravljanja mikrokontrolerskom implementacijom na realnoj hardverskoj strukturi vođenog objekta regulacije.

8. ZAKLJUČAK DOKTORSKOG RADA

Znanstveni doprinos ove doktorske disertacije, prema mišljenju autora, ogleda se u slijedećem:

1. Učinjene promjene u postojećoj strukturi **NAR-a**, uvođenjem novog oblika funkcije pripadnosti ulaznih neizrazitih skupova, kao i stupnjevanje aktivacijske funkcije sa stupnjevanom pripadnošću ulazne varijable i-tom neizrazitom skupu, rezultirale su poboljšanjem postojeće regulacijske karakteristike **NAR-a**.
2. S ovim promjenama u postojećoj strukturi stečeni su potrebni preduvjeti za predlaganje postupka samoorganiziranja slobodnih parametara **NAR-a**. Po prvi put kod suvremenog analitičkog pristupa neizrazitoj regulaciji predlaže se u **OFF-line** modu rada, samoorganiziranje u smislu adaptacije slobodnih parametara **PNAR-a** modificiranom gradijentnom metodom. Ista se zasniva na gradijentu pogreške slijeđenja nominalne trajektorije u prostoru unutarnjih upravljanih koordinata. Ispravnost predloženog postupka, kao i rad **PNAR-a**, provjerena je simulacijom.
3. Predloženi su kriteriji koji garantiraju stabilnost nelinearnog algoritma adaptacije i ograničenja koja garantiraju stabilnost algoritma regulacije. Provedena je analiza utjecaja slobodnih parametara adaptacije na neizrazita svojstva **PNAR-a** u faznoj ravnini stanja. Predložene su osnovne konfiguracije **PNAR-a** kao nelinearnog diskretnog **PD**, **PI** i **PID** regulatora i predložen postupak podešavanja integralne vrijednosti pojačanja.
4. Uvedena je **MKNUD-a** čime je osigurano vođenje **OR** u realnom vremenu. Na osnovu mjerne pogreške pozicije u uvjetima postojanja stacionarne i nestacionarne mjerne smetnje tipa »bijelog šuma« predložen je pri **ON-line** vođenju **AMR-a** zadanom nominalnom trajektorijom, neizraziti mehanizam adaptacije slobodnih parametara i Kalmanovih pojačanja.
5. Doprinosi navedeni prethodnim točkama vode ka ispunjenju zadatka postavljenog hipotezom rada ove doktorske disertacije. Izgrađeno je zadovoljavajuće samoorganiziranje u smislu adaptacije njegovih parametara i poboljšane su regulacijske karakteristike **PNAR-a**, sa svrhom što uspješnijeg vođenja **AMR** definiranom nominalnom trajektorijom.

LITERATURA

- [1.] Zadeh, L.A, "From circuit theory to systems theory", *Proceedings Institute of Radio Engineers*, Vol. 50 1962, pp. 856-865.
- [2.] Zadeh, L.A., Fuzzy sets, *Information and Control*, Vol. 8 1965, pp. 338-352.
- [3.] Zadeh, L.A, Fuzzy algorithm, *Information and control*, Vol.12 1963, pp. 94-108.
- [4.] Zadeh, L.A, "Outline of the new approach to the analysis of complex systems and decision processes", *IEEE Transaction on Systems, Man and Cybernetics*, Vol. 3(1):pp. 28-44, 1973.
- [5.] Assilian, S., Mamdani, E. H. "Learning control algorithms in real dynamic systems", 4th *IFAC/IFIP International conference on digital computer applications to process control*, Zürich, 1974, Lecture notes in economics and mathematical systems, Vol. 93, Springer Verlag, 1974.
- [6.] Mamdani, E. H., Assilian, S. "An experiment in linguistic synthesis with a fuzzy logic controller", *International Journal Man-machine studies*, Vol. 7, pp. 1-13, 1975.
- [7.] Mamdani, E. H. "Application of fuzzy algorithms for control of simple dynamic plant", *Proceedings of the IEE*, 121(12), pp. 1585-1588, 1974.
- [8.] Tong, R. M. "A control engineering review of fuzzy systems", *Automatica*, Vol.13, pp. 559-569, 1977.
- [9.] King, P. J., Mamdani, E. H. "The Application of Fuzzy Control Systems to industrial Processes", *Automatica*, Vol. 13, pp.235-242, 1977.
- [10.] Kickert, W.J.M., Mamdani, E. H. "Analysis of a fuzzy logic controller", *Fuzzy sets and systems*, Vol 1., pp. 29-44, 1978.
- [11.] Chang, S. S. L., Zadeh, L. A. "On fuzzy mapping and control", *IEEE Transaction on Systems, Man and Cybernetics*, Vol. 2, pp.30-34, 1972.
- [12.] Maier, J., Sherif, Y. S. "Application of fuzzy set theory", *IEEE Transaction on systems, man and cybernetics*, Vol. 15(1): pp.175-189, 1985.
- [13.] Dutta, S. "Fuzzy logic application: technological and strategic issues", *IEEE Transactions on engineering management*, Vol 40(3): pp.237-254, 1993.
- [14.] Driankov, D., Hellendoorn, H., Reinfrank, M. *An introduction to Fuzzy Control*, Springer Verlag, Berlin, 1993.
- [15.] Kosko, B. *Fuzzy Engineering*, Prentice Hall, New Jersey, 1996.
- [16.] Chen, J. Q., Lu, J. H., Chen, L. J. "An on-line identification algorithm for fuzzy systems", *Fuzzy sets and systems*, Vol 64 pp. 63-72, 1994.

-
- [17.] Pedrycz, W. »Identification in Fuzzy Systems«, *IEEE Transaction on Systems, Man and Cybernetics*, 14(2), 361-366, 1984.
 - [18.] Yoshinari, Y., Pedrycz, W., Hirota, K. "Construction of fuzzy models through clustering techniques", *Fuzzy sets and systems*, Vol 54, pp 157-165, 1993.
 - [19.] Pharm, T.D., Valliappan, S. "A least squares model for fuzzy rules of inference", *Fuzzy sets and systems*, Vol 64, pp. 207-212, 1994.
 - [20.] Chalam, V. V., *Adaptive Control Systems – Techniques and Applications*, Marcel Dekker, Inc., New York and Basel, 1987.
 - [21.] Kaufman H., Bar-Kana I., Sobel K., *Direct Adaptive control Algorithms: Theory and Applications*, Springer Verlag, New York. 1994.
 - [22.] Butler, H. *Model reference adaptive control – from theory to practice*, Prentice Hall, New York, 1992.
 - [23.] Yin, T. K. and Lee, C. S. G. Fuzzy model- reference adaptive control. *IEEE Transaction on Systems, Man and Cybernetics* 25(12), pp. 1606-1615, 1995.
 - [24.] Pacini, P.J. and Kosko, B. Adaptive fuzzy systems for target tracking. *IEEE Intelligent Systems Engrg.* 1(1), pp. 3-21, 1992.
 - [25.] Nozaki, K., Ishibuchi, H., Tanaka H., Adaptive fuzzy rule-based classification systems, *IEEE Trans. Fuzzy Systems* 4 (3) 1996, pp. 238-250.
 - [26.] Guo, S., Peters, L. and Surmann, H. "Design and Application of an Analog Fuzzy Logic Controller", *IEEE Transaction on Fuzzy Systems* 4(4), pp. 429-438, 1996.
 - [27.] Patyra, M. J., Grantner, J. L. and Koster, K. "Digital Fuzzy Logic Controller: Design and Implementation", *IEEE Transaction on Fuzzy Systems* 4(4), pp. 439-459, 1996.
 - [28.] Nakamura, K., Sakashita, N., Nitta, Y., Shimomura, K. and Tokuda, T. "Fuzzy Inference and Fuzzy Inference Processor", *IEEE Micro*, October, pp. 37-48, 1993.
 - [29.] Takagi, T., Sugeno, M. "Fuzzy identification of system and its applications to modeling and control", *IEEE Transactions on Systems, Man and Cybernetics* 15(1), pp. 116-132, 1985.
 - [30.] Novakovic, B. An Approach to Design of an Adaptive Fuzzy Set for Fuzzy Control. In *Proceedings of the 6th International DAAAM Symposium*, Katalinic, B. (Ed.) , pp. 243-244, Technical University of Krakow, Poland, 1995.
 - [31.] Novaković, B., Fuzzy Logic Robot control Synthesis Without Any Rule Base, *IEEE Proc. Of the 8th Intern. Conf. On Advanced Robotics, ICAR' 97*, 97TH8308, Monterey, California, U.S.A., pp. 141-146, 1997.
 - [32.] Novakovic, B. Adaptive Fuzzy Logic Control Synthesis without a Fuzzy Rule Base, In *Fuzzy Theory Systems*, ed. by C.T. Leondes, foreword by L.A. Zadeh, vol. 2, chapt. 28, pp. 781-808, Academic Press, New York, 1999.
 - [33.] Novakovic, B., Vranjes, B., Kasac, J., Majetic, D., Brezak, D., An Adaptive Fuzzy Robot Control Without a Fuzzy Rule Base, *Proc. Of 15th IFAC World Congress on Automatic Control*, Barcelona, Spain, 2002.

-
- [34.] Novaković, B., Majetić D., N.Blažević, An Analytic Approach to Fuzzy Logic Robot Control Synthesis, Symposium on Robot Control, Vol.2,p.p. 391-396, Nantes,1997.
 - [35.] Kekez, A. "Sinteza upravljanja fleksibilnim robotom s neizrazito-logičkim regulatorom", Magistarski rad, FSB Zagreb, 1998.
 - [36.] Canudas de Wit, C. & Roskam, R. (1991). Path Following of a 2-DOF Wheeled Mobile Robot Under Path and Input Torque Constraints, *International Conference on Robotics and Automation*, pp. 1142-1147, Sacramento, 1991., California.
 - [37.] Koh, K.C. & Cho, H.S. (1994). A Path Tracking Control System for Autonomous Mobile Robots: An Experimental Investigation, *Mechatronics*, No. 8, 1994., pp. 799-820.
 - [38.] Kirola, M.»Projektiranje upravljačkog sustava mobilnog robota«, Diplomski rad, FSB Zagreb, 1995, mentor prof.dr.sc. Mladen Crneković.
 - [39.] Crnekovic, M. & Kirola, M. (1997). Path Tracking Control Algorithm for Autonomous Mobile Robot, *Proceedings of the 4th International Conference on Production Engineering, CIM 1997*, Opatija, Croatia.
 - [40.] Kirola, M. »Sinteza neizrazitog regulatora za mobilni robot«, Magistarski rad, FSB Zagreb, 2002, mentor prof.dr.sc. Branko Novaković.
 - [41.] Kirola, M. Comparative study of controllers for autonomous mobile robot, *Proceedings of the 15th International DAAAM Symposium*, pp 211-212, ISBN 3-901509-42-9, Editor B. Katalinic, Published by DAAAM International, Vienna, November 2004., Austria.
 - [42.] Kirola, M. Fuzzy logic control (FLC) for autonomous mobile robot, *Proceedings of the 13th International DAAAM Symposium*, pp 263-264, ISBN 3-901509-29-1, Editor B. Katalinic, Published by DAAAM International, Vienna, October 2002., Austria.
 - [43.] Filev, D. P., Yager, R. R.: On the analisis of fuzzy controllers, *Fuzzy sets and systems*, Vol 68, pp. 39-66, 1994.
 - [44.] Mon, D. L. and Cheng, C. H., Fuzzy systems reliability analisis for components with different membership functions, *Fuzzy sets and systems*, Vol 64, pp. 145-157, 1994.
 - [45.] Pedrycz, W., Why triangular membership functions, *Fuzzy sets and systems*, Vol 64, pp. 21-30, 1994.
 - [46.] Lotfi, A, Tsoi, A.C., Learning fuzzy inference system using an adaptive membership function scheme, *IEEE Transactions on Systems, Man and Cybernetics*, Part B: Cybernetics 26(2), pp. 326-331, 1996.
 - [47.] Lotfi, A., Andersen, H. C., and Tsoi, A. C. Matrix formulation of fuzzy rule-based systems. *IEEE Transactions on Systems, Man and Cybernetics*. B cybernet. 26(2):332-340,1996.
 - [48.] Tyan, C. Y., Wang, P. P., Bahler, D. R. and Rangaswamy, S. P. A new methodology of fuzzy constraint-based controller design via constraint- network processing. *IEEE Transaction Fuzzy Systems* 4(2): 166-178, 1996.
 - [49.] Hohle, U. and Stout, L.N., Foundations of fuzzy sets, *Fuzzy sets and systems* Vol 40, pp. 257-296, 1991.

-
- [50.] Runkler., T. A. Selection of Appropriate Defuzzification Methods Using Application Specific Properties, *IEEE Transactions on Fuzzy Systems*, 5(1), pp. 72-79, 1997.
 - [51.] Guely, F. and Siarry P. A centred formulation of Takagi-Sugeno rules for improved learning efficiency, *Fuzzy sets and systems*, Vol 62, pp.277-285, 1994.
 - [52.] Matlab, Fuzzy toolbox, 2002.
 - [53.] Ishibuchi, H., Noyaki, K., Tanaka, H., Hosaka, Y. and Matsuda, M. Empirical study on learning in fuzzy systems by rice taste analysis, *Fuzzy sets and systems*, Vol 64. pp. 129-144, 1994.
 - [54.] Maeda, M. and Murakami, S. A self-tuning fuzzy controller, *Fuzzy sets and systems*, Vol 51 pp. 29-40, 1992.
 - [55.] Jee, S. and Koren, Y. A self-organizing fuzzy logic control for friction compensation in feed drives, *Proceedings of the American Control Conference*, Seattle, pp. 205-209, 1995.
 - [56.] He, S. Z., Tan, S., Hang, C. C. and Wang, P. Z. Control of dynamical processes using on-line rule-adaptive fuzzy control system, *Fuzzy sets and systems*, Vol 54, pp. 11-22, 1993.
 - [57.] Šurina, T. *Automatska regulacija*, Školska knjiga, Zagreb, 1991.
 - [58.] Kuljača, Lj. i Vukić, Z. *Automatsko upravljanje sistemima*, Školska knjiga, Zagreb, 1985.
 - [59.] Novaković, B. *Regulacijski sistemi*, Liber, Zagreb, 1985.
 - [60.] Malki, H.A., Li, H., Chen, G., New design and stability analysis of fuzzy proportional derivative control systems, *IEEE Trans. on Fuzzy Systems* 2 (4) 1994, pp. 245-254.
 - [61.] Tseng, H. C. and Hwang, V. H. Servocontroller Tunning with Fuzzy Logic, *IEEE Trans. on Control Systems Technology*, 1(4): pp.262-269, 1993.
 - [62.] Kim, S., Cho, Y., Park, M., A multi-rule-base controller using robust property of a fuzzy controller and its design method *IEEE Transaction on Fuzzy Systems* 4 (3), pp. 315-327, 1996.
 - [63.] Kirola, M.; Brezak, D. & Majetic, D. Neural network in the Autonomous mobile Robot Path Tracking Control, *Proceedings of the 12th International DAAAM Symposium*, Katalinic, B. (Ed.), pp 223-224, ISBN 3-901509-19-4, Vienna, October 2001., Austria.
 - [64.] Lin, C. T. and Lu, Y. C. A neural fuzzy systems with fuzzy supervised learning, *IEEE Transaction on SMC*, 26(5): pp.744-763, 1996.
 - [65.] Homaifar, A., McCormick, E., Simultaneous design of membership function and rule sets for fuzzy controllers using genetic algorithms, *IEEE Trans. on Fuzzy Systems* 3(2), pp. 129-139, 1995.
 - [66.] Wei, Li. *A Method for Design of a Hibrid Neuro-Fuzzy Control System Based onBehavior Modeling*, *Fuzzy System*, 5(1), 1997.
 - [67.] He, S. Z., Tan, S., Xu, F. L. and Wang, P.Z. Fuzzy self-tuning of PID controller, *Fuzzy Sets and Systems*, Vol 56, pp. 37-46, 1993.

-
- [68.] Wang, P. The interpretation of fuzziness, *IEEE Transactions on Systems, Man and Cybernetics*, B Cybernet. 26 (2): 321-326, 1996.
 - [69.] Self, K. Designing with fuzzy logic, *IEEE Spectrum*, pp. 42-44 November, 1990.
 - [70.] Gupta, M. M. and Qi, J. Theory of T-norms and fuzzy inference methods, *Fuzzy sets and systems*, Vol. 40, pp. 431-451, 1991.
 - [71.] Pedrycz, W. Processing in relational structures: Fuzzy relational equations, *Fuzzy sets and systems*, Vol 40, pp. 77-106, 1991.
 - [72.] Donlagić, D. i koautori, *Osnove projektiranja neizrazitih (Fuzzy) regulacijskih sustava*, KoREMA, ISBN 953-6037-05-X, Maribor, 1994.
 - [73.] Procyk, T. J. and Mamdani, E. H. A linguistic self-organizing process controller, *Automatica*, Vol. 15, pp.15-30, 1979.
 - [74.] Novaković, B. *Metode vođenja tehničkih sistema*, Školska knjiga, Zagreb, 1990.
 - [75.] Šurina, T. i Crneković, M. *Industrijski roboti*, Školska knjiga, Zagreb, 1990.
 - [76.] Netušil, A.V. *Teorija avtomatičkog upravljenja*, Visšaja škola, Moskva, 1976.
 - [77.] Doleček, V. i Karabegović, I. *Robotika*, Tehnički fakultet, Bihać, 2002.
 - [78.] Astapov Ju. M., Medvedov V. S. *Statičeskaja teorija system avtomatičeskovo regulirovania i upravljenja*, Nauka, Moskva, 1982.
 - [79.] Sage A. P. and Melsa J. L. *Estimation theory*, Mc Graw Hill, USA, 1971.
 - [80.] Isermann R., *Digital control Systems*, Springer-Verlag, Berlin, 1981.
 - [81.] Ordonez, R., Zumberge, J., Spooner, J.T., Passino K.M., Adaptive fuzzy control: experiments and comparative analysis, *Ieee Trans. on Fuzzy Systems* 5 (2) 1997, pp. 167-188.
 - [82.] Kim, E., Park, M., Ji, S., and Park, M. A new approach to fuzzy modeling. *IEEE Trans. Fuzzy Systems* 5(3): 328-337, 1997.
 - [83.] Mathematica, *User's Manual*, 2003.
 - [84.] Omron, *User's Manual*, 2004.
 - [85.] Novaković, B., Fuzzy Logic Control Synthesis Without Any Rule Base, *IEEE Trans. on Systems, Man, and Cybernetics*, Vol.29, No.3, pp. 459-466, June 1999.
 - [86.] Novaković, B.; Šćap, D.; Novaković, D., An Analytic Approach to Fuzzy Robot Control Synthesis, *Engineering Applications of Artificial Intelligence*, Vol. 13, pp.71-83, 2000.
 - [87.] Vukić, Z. i Kuljača, Lj. *Automatsko upravljanje - analiza linearnih sustava*, Kigen d.o.o., Zagreb, 2005.
 - [88.] Tomas, P *Osnove automatizacije*, ALFA-2,Dubrovnik, 2002
 - [89.] Kreyszig, E. *Advanced engineering mathematics*, 8-th edition, Wiley, 1999

ŽIVOTOPIS

Marijo Kirola rođen je u Dubrovniku 11. lipnja 1971. godine, gdje je završio osnovnu i srednju školu te stekao obrazovni profil elektrotehničara, sa smjerom:

Elektrostrojarstvo i energetika, proizvodnja i održavanje električnih strojeva i uređaja.

Fakultet strojarstva i brodogradnje sveučilišta u Zagrebu upisuje 1990. godine, na kojem se opredjeljuje za proizvodni smjer s užim stručnim izborom iz područja strojarske automatike. Zanimajući se za područje robotike napravio je diplomski rad na temu:

»Projektiranje upravljačkog sustava mobilnog robota« .

s kojom u prosincu 1995. godine i uspješno diplomira. U prosincu 1999. godine upisuje poslijediplomski studij smjer robotike i automatike na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu. U siječnju 2002. godine obranio je magistarski rad pod naslovom

»Sinteza neizrazitog regulatora za mobilni robot« .

Svoj daljnji znanstveni rad nastavlja kao asistent na novoosnovanom Sveučilištu u Dubrovniku, te 2003. godine na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu prijavljuje temu doktorske disertacije,

»Samoorganiziranje neizrazitog analitičkog regulatora pri vođenju mobilnog robota« .

BIOGRAPHY,

Marijo Kirola was born on June 11, 1971 in Dubrovnik where he also completed elementary and high school with the curriculum for electrical technicians in the field of Electrical Engineering and Power Plants, production and maintenance of electrical machines and devices.

In 1990 he was enrolled in the Faculty of Mechanical Engineering and Naval Architecture of the University of Zagreb with major in machine automata theory. As his main interest is in the field of robotics his graduation paper was entitled, Projecting of Mobile Robot Controlling System with which he successfully graduated in 1995.

In December 1999 he was enrolled in post graduate studies in robotics and automation at the Faculty of Mechanical Engineering and Naval Architecture of the University of Zagreb. In January 2002 he discussed his thesis for Master's degree entitled Synthesis of Fuzzy Logic Controller for Mobile Robot.

He is continuing his scientific work assistant lecturer at the newly founded University of Dubrovnik. In 2003 he was declared his doctoral thesis titled

“Self-organizing of fuzzy analytic controller in mobile robot path tracking control” .

at the Mechanical Engineering and Naval Architecture of the University of Zagreb.

PRILOZI

Br. Priloga	Program	Funkcija programa
1	<i>aFLC.m</i>	Poboljšani Neizraziti Analitički Regulator (PNAR)
2	<i>odrFB.m</i>	Određivanje nelinearne bijekcijske zavisnosti $u_n = Ye(e_n, F, B)$ između slobodnih parametara metodom tangenti.
3	<i>ppdFB.m</i>	Početno podešavanje (ugađanje) PNAR -a
4	<i>gensus.m</i>	Generiranje matrica Autonomnog Robotskog Sustava (AMR) sustava
5	<i>spnar.m</i>	Postupak samoorganiziranja slobodnih parametara PNAR -a
6	<i>mknud.m</i>	Formiranje Memorijske Kartice Neizrazitog Upravljačkog Djelovanja (MKNUD)
7	<i>aFLC_d.m</i>	Diskretni oblik PNAR -a
8	<i>riccati.m</i>	Postupak rješavanja nelinearne diferencijalne matrične Rikatijske jednačine.

```
function IZLAZ=aFLC(e,de,PARAMETRI)
```

```
%-----
%  MODUL: aFLC.m
%-----
%  PROGRAM: aFLC.m
%-----
%  FUNKCIJA: Izračunavanje izlazne vrijednosti PNAR-a na osnovu definiranih pogreški po poziciji i brzini.
%-----
%  ULAZNE VARIJABLE:   e - pogreška po poziciji
%                      de - pogreška po brzini
%                      PARAMETRI - definiranje parametara vidjeti (odrFB.m)
%-----
%  IZLAZNE VARIJABLE:
%  IZLAZ=[OsFe,OsBe,OsFde,OsBde,OsBFe,OsBFde,Yizlaz]
%  OsFe - Osjetljivost F parametra funkcije preslikavanja ulaznog NS pozicije
%  OsBe - Osjetljivost B parametra funkcije preslikavanja ulaznog NS pozicije
%  OsFde - Osjetljivost F parametra funkcije preslikavanja ulaznog NS brzine
%  OsBde - Osjetljivost B parametra funkcije preslikavanja ulaznog NS brzine
%  OsBFe - Osjetljivost B parametra o F parametru za ulaznu pogrešku pozicije
%  OsBFde - Osjetljivost B parametra o F parametru za ulaznu pogrešku brzine
%  Yizlaz - Izlazna vrijednost iz PNAR - a
%-----
%
%  Kirola, M. 10-23-2003
%  Napravljeno u Dubrovniku (c), 2003-2005
%-----
```

```
% Učitavanje parametara
F1=PARAMETRI(1,1);
F2=PARAMETRI(2,1);
Be1=PARAMETRI(1,2);
Be2=PARAMETRI(2,2);
alfa1=PARAMETRI(1,3);
alfa2=PARAMETRI(2,3);
k1i=PARAMETRI(1,4);
k2i=PARAMETRI(2,4);
T1i=PARAMETRI(1,5);
T2i=PARAMETRI(2,5);
Ep1=PARAMETRI(3,1:7);
Ep2=PARAMETRI(4,1:7);
T1=PARAMETRI(5,1:7);
T2=PARAMETRI(6,1:7);
```

```
IZLAZ=zeros(1,7);
Xc1=[0 0 0 0 0 0 0];
Xc2=[0 0 0 0 0 0 0];
Um=15.0; %maksimalni upravljački napon
S=[];
N1=size(Ep1,2);
N2=size(Ep2,2);
g2e=0.03;
g2de=0.03;
g1e=0.96;
g1de=0.96;
```

```
for n=1:N1
    Xo1(n)=Xc1(n)-T1(n)/2;
    Xe1(n)=Xc1(n)+T1(n)/2;
End
```

```

for n=1:N2
    Xo2(n)=Xc2(n)-T2(n)/2;
    Xe2(n)=Xc2(n)+T2(n)/2;
End

u1=e;
for n=1:N1
    Xa1(n)=Xc1(n)-T1(n)/(2*Ep1(n));
    Xb1(n)=Xc1(n)+T1(n)/(2*Ep1(n));
    if u1>=Xo1(n) & u1<Xa1(n)
        S(n)=(1-cos((2*pi*Ep1(n)*(u1-Xc1(n)+T1(n)/2))/((Ep1(n)-1)*T1(n))))/2;
        S(n)=S(n)/exp(Be1*Ep1(n)*abs(u1));
        OsBe1(n)=-S(n)*(Ep1(n)*abs(u1));
    elseif u1>=Xa1(n) & u1<Xb1(n)
        S(n)=1;
        S(n)=S(n)/exp(Be1*Ep1(n)*abs(u1));
        OsBe1(n)=-S(n)*Ep1(n)*abs(u1);
    elseif u1>=Xb1(n) & u1<=Xe1(n)
        S(n)=(1-cos((2*pi*Ep1(n)*(-u1+Xc1(n)+T1(n)/2))/((Ep1(n)-1)*T1(n))))/2;
        S(n)=S(n)/exp(Be1*Ep1(n)*abs(u1));
        OsBe1(n)=-S(n)*(Ep1(n)*abs(u1));
    else
        S(n)=0;
        OsBe1(n)=0;
    end
end
Omega1=sum(S.^g1e);
Yc1=1-Omega1/N1;
dY1=Um*F1*(1+abs(u1)^alfa1)*(sign(u1)*Yc1);
%Osjetljivost B i F parametra
SumOsBe1=sum(OsBe1);
OsBe1=-SumOsBe1*Um*F1*(1+abs(u1)^alfa1)*sign(u1)/N1;
OsF1=Um*(1+abs(u1)^alfa1)*(sign(u1)*Yc1);

%-----

u2=de;
for n=1:N2
    Xa2(n)=Xc2(n)-T2(n)/(2*Ep2(n));
    Xb2(n)=Xc2(n)+T2(n)/(2*Ep2(n));

    if u2>=Xo2(n) & u2<Xa2(n)
        S(n)=(1-cos((2*pi*Ep2(n)*(u2-Xc2(n)+T2(n)/2))/((Ep2(n)-1)*T2(n))))/2;
        S(n)=S(n)/exp(Be2*Ep2(n)*abs(u2));
        OsBe2(n)=-S(n)*(Ep2(n)*abs(u2));
    elseif u2>=Xa2(n) & u2<Xb2(n)
        S(n)=1;
        S(n)=S(n)/exp(Be2*Ep2(n)*abs(u2));
        OsBe2(n)=-S(n)*Ep2(n)*abs(u2);
    elseif u2>=Xb2(n) & u2<=Xe2(n)
        S(n)=(1-cos((2*pi*Ep2(n)*(-u2+Xc2(n)+T2(n)/2))/((Ep2(n)-1)*T2(n))))/2;
        S(n)=S(n)/exp(Be2*Ep2(n)*abs(u2));
        OsBe2(n)=-S(n)*(Ep2(n)*abs(u2));
    else
        S(n)=0;
        OsBe2(n)=0;
    end
end
end

```

```

Omega2=sum(S.^g1de);
Yc2=1-Omega2/N2;
dY2=Um*F2*(1+abs(u2)^alfa2)*(sign(u2)*Yc2);
%Osjetljivost B i F parametra
SumOsBe2=sum(OsBe2);
OsBe2=-SumOsBe2*Um*F2*(1+abs(u2)^alfa2)*sign(u2)/N2;
OsF2=Um*(1+abs(u2)^alfa2)*(sign(u2)*Yc2);

Fi1=(Omega1^g2e)*T1i*(1+k1i)/((Omega1^g2e)*T1i*(1+k1i)+(Omega2^g2de)*T2i*(1+k2i));
Fi2=(Omega2^g2de)*T2i*(1+k2i)/((Omega1^g2e)*T1i*(1+k1i)+(Omega2^g2de)*T2i*(1+k2i));
Yizlaz=Fi1*dY1+Fi2*dY2;
OsBe=OsBe1*Fi1;
OsFe=OsF1*Fi1;
OsBde=OsBe2*Fi2;
OsFde=OsF2*Fi2;

IZLAZ=[OsFe,OsBe,OsFde,OsBde,Yizlaz];

```

```
function [Parametar_V]=odrFB(BF,en,Un,Upog,M)
```

```
%-----
%  MODUL: odrFB.m
%-----
%  PROGRAM: odrFB.m
%-----
%  FUNKCIJA: Određivanje nelinearne bijekcijske zavisnosti un=Ye(en,F,B), između slobodnih
%             parametara metodom tangenti.
%-----
%  ULAZNE VARIJABLE: BF - B ili F parametar
%
%                     en - pogreška (izraz 2.52)
%
%                     Un - nominalni napon pri stacionarnom gibanju AMR pravocrtnom putanjom.
%
%                     Upog - dozvoljena pogreska algoritma izra?unavanja
%
%                     M - Mod rada (M=1 odre?uje se B parametar, za M=2 izra?unavanje F parametra)
%-----
%  IZLAZNA VARIJABLA:  B parametar za M=1, ili F parametar za M=2.
%-----
%
%  Kirola, M. 02-05-2004
%  Napravljeno u Dubrovniku (c), 2003-2005
%-----
```

```
% Zadavanje parametara PARAMETRI PNAR-a:
```

```
% 1. red [F Be alfa k Ti 0 0] - parametri vezani za ulaznu varijablu pogrešku pozicije
% 2. red [F Be alfa k Ti 0 0] - parametri vezani za ulaznu varijablu pogrešku brzine
% 3. red Esilo parametar neizrazitih skupova ulazne varijable pogreške pozicije
% 4. red Esilo parametar neizrazitih skupova ulazne varijable pogreške brzine
% 5. red Vektor baze ulaznih neizrazitih skupova ulazne varijable pogreške pozicije
% 6. red Vektor baze ulaznih neizrazitih skupova ulazne varijable pogreške brzine
```

```
PARAMETRI=[3.5 0.15 0 0.5 0.75 0 0;
            3.5 0.15 0 0.5 0.75 0 0;
            17 17.2 19 21 31 65 122;
            17 17.2 19 21 31 65 122;
            2.05 2.05 2.05 2.05 2.05 2.05 2.05;
            2.05 2.05 2.05 2.05 2.05 2.05 2.05];
```

```
e=en; %nominalna vrijednost pogreške
```

```
de=0; %stacionarnog gibanja
```

```
inic_parametar=0.01;
```

```
if M==2
    j=1;
    PARAMETRI(1,2)=BF;
elseif M==1
    j=2;
    PARAMETRI(1,1)=BF;
End

%Iteracijski metod tangenti
PARAMETRI(1,j)=inic_parametar;
IZLAZ=aFLC(e,de,PARAMETRI);
ur=IZLAZ(1,5);
Os_parametar=IZLAZ(1,j);
InvOs_parametar=Os_parametar^(-1);
deltaUr=Un-ur;

k=0;
while abs(deltaUr)>=Upog
    k=k+1;
    PARAMETRI(1,j)=PARAMETRI(1,j)+InvOs_parametar*deltaUr;
    IZLAZ=aFLC(e,de,PARAMETRI);
    ur=IZLAZ(1,5);
    deltaUr=Un-ur;
    if k>=100000
        disp(' ')
        disp('Prekoracenje dopuštenog broja iteracija k=100000')
        break
    end
end
end
Parametar_V=PARAMETRI(1,j);
```

```
function [F,B]=ppdFB(Un,Kn,Eta,Upog)
```

```
%-----
%  MODUL:  ppdFB.m
%-----
%  GLAVNI PROGRAM:  ppdFB.m
%-----
%  FUNKCIJA:  Početno ugađanje PNAR-a, određivanjem F i B parametra uz zadani (nulti) stupanj neizrazitog
%              djelovanja Eta
%-----
%  ULAZNE VARIJABLE:  Un - nominalni napon pri stacionarnom gibanju AMR pravocrtnom putanjom.
%                      Kn - parametar skupa (familije) karakterističnih krivulja
%                      Eta - stupanj neizrazitog djelovanja PNAR-a
%                      Upog - dozvoljena pogreska algoritma izračunavanja
%-----
%  IZLAZNA VARIJABLA:  Uređeni par parametara (F,B)
%-----
%
%  Kirola, M.  03-01-2004
%  Napravljeno u Dubrovniku  (c),  2003-2005
%-----

% Zadavanje parametara PNAR-a (vidi odrFB.m),
PARAMETRI=[3.5 0.15 0 0.5 0.75 0 0;
            3.5 0.15 0 0.5 0.75 0 0;
            17  17.2  19  21  31 65 122;
            17  17.2  19  21  31 65 122;
            2.05 2.05 2.05 2.05 2.05 2.05 2.05;
            2.05 2.05 2.05 2.05 2.05 2.05 2.05];

Kpn=Kn;
en=Un/Kn;
den=0; %stacionarno gibanje AMR pravocrtnom putanjom
en0=en/100;
pogreska=0.01; %pogreška izračunavanja algoritma odrFB
Uzvj_nivo=(1+Eta)*Kpn*en0;
B=0;
deltaU=Uzvj_nivo;
```

```
k=0;
while abs(deltaU)>=Upog
    k=k+1;
    %govori o nelinearnoj bijekcijskoj zavisnosti B od F
    Fe=odrFB(B,en,Un,pogreska,2);
    PARAMETRI(1,2)=B;
    PARAMETRI(1,1)=Fe;
    IZLAZ=aFLC(en0,den,PARAMETRI);
    Urzvj=IZLAZ(1,5);
    deltaUrvj=Uzvj_nivo-Urvj;
    deltaU=deltaUrvj;
    INVBetaOs=(IZLAZ(1,2))^-1;
    PARAMETRI(1,2)=PARAMETRI(1,2)+INVBetaOs*deltaUrvj;
    deltaUrvj=Uzvj_nivo-Urvj;
    B=PARAMETRI(1,2);
    if k>=100000
        disp(' ')
        disp('Prekoracenje dopuštenog broja iteracija k=100000')
    break
end
end
F=PARAMETRI(1,1);
```

```
function [A,B,C,D,hiiu,hiju]=gensus(mr,dmr,dql,dqd,IN)
```

```
%-----
%  MODUL:  gensus.m
%-----
%  PROGRAM:  gensus.m
%-----
%  FUNKCIJA:  Generiranje matrica AMR sustava
%-----
%  ULAZNE VARIJABLE:
%  mr - masa robota
%  dmr - promjena mase robota
%  dql - kutna brzina lijevog pogonskog kotača
%  dqd - kutna brzina desnog pogonskog kotača
%  IN=[IN1 IN2 IN3]
%  IN1=1 spregnuti multivarijabilni sustav,
%  IN1=0 deкупловани, raspregnuti multivarijabilni sustav
%  IN2=1 uzet tustinov nelinearni model trenja,
%  IN2=2 uzet samo linearni dio Tustinovog trenja,
%  IN2=0 Nema trenja u zglobovima robotskog mehanizma
%  IN3=1 Postoji varijacija mase mobilnog robotskog sustava po nekoj zavisnosti dmr.
%-----
%  IZLAZNA VARIJABLA:
%  [A,B,C,D,hiiu,hiju] A - matrica koeficijenata sustava dim(4x4)
%                      B - matrica ulaza sustava dim(4x2)
%                      C - matrica izlaza sustava dim (2x4)
%                      D - matrica prijenosa sustava dim(2x2)
%                      hiiu - ukupni vlastiti dinamički moment tromosti
%                      hiju - ukupni unakrsni dinamički momenti tromosti
%-----
%
%  Kirola, M. 11-02-2003
%  Napravljeno u Dubrovniku (c), 2003-2005
%-----
```

```
Jv=0.13;
Dv=0.43;
IN1=IN(1);
IN2=IN(2);
IN3=IN(3);

if IN3==1
    dmr=dmr; % treba biti vremenska funkcija promjene mase
else
    dmr=0;
end

D=0.8;
d=0.2;
Cm=0.32;
Ce=0.32;
R=1.6;
N=10;
CM=Cm*N;
CE=Ce*N;
```

```

Jr=mr*(D/2)^2/2;
dJr=dmr*(D/2)^2/2;
hii=(mr*d^2/16)+(Jr/4)*(d/D)^2;
hij=( (mr*d^2/16)-(Jr/4)*(d/D)^2 )*IN1;
dhii=(dmr*d^2/16)+(dJr/4)*(d/D)^2;
dhij=( (dmr*d^2/16)-(dJr/4)*(d/D)^2 )*IN1;

% Podaci za Tustinovo trenje u zglobovima robotskog mehanizma
Dz=0.05; %koeficijent viskoznoznog trenja u zglobovima
Dd=0.01; %dinamicko trenje
Ds=0.1; %staticko trenje
E=0.07; %Stribeckova brzina

%Racunanje promijenjivog nelinearnog momenta trenja u zglobovima robotskog mehanizma
Tdeltal=sign(dql)*(Dd+(Ds-Dd)*exp(-abs(dql)/E));
Tdeltad=sign(dqd)*(Dd+(Ds-Dd)*exp(-abs(dqd)/E));

%-----Koeficijenti diferencijalne jednadzbe
KRii=CM/R*(Jv+hii+dhii)/((Jv+hii+dhii)^2-(hij+dhij)^2);
KQii=(CM*CE/R+Dv)*(Jv+hii+dhii)/((Jv+hii+dhii)^2-(hij+dhij)^2);
KRij=CM/R*(hij+dhij)/((Jv+hii+dhii)^2-(hij+dhij)^2);
KQij=(hij+dhij)*(CM*CE/R+Dv)/((Jv+hii+dhii)^2-(hij+dhij)^2);

hiiu=hii+dhii;
hiju=hij+dhij;

if IN2==1
    if dql==0
        deltal=sign(dql)*Dd;
    else
        deltal=Dz+Tdeltal/dql;
    end
    if dqd==0
        deltad=sign(dqd)*Dd;
    else
        deltad=Dz+Tdeltad/dqd;
    end
elseif IN2==2
%Koristeći se linearnim modelom Tustinovog trenja
    deltal=Dz;
    deltad=Dz;
else
    deltal=0;
    deltad=0;
end

DKQ11=KRii*deltal;
DKQ12=KRij*deltad;
DKQ21=KRij*deltal;
DKQ22=KRii*deltad;

%-----
A=[0 0 1 0; 0 0 0 1; 0 0 -(KQii+DKQ11) (KQij+DKQ12); 0 0 (KQij+DKQ21) -(KQii+DKQ22)];
B=[0 0;0 0;KRii -KRij;-KRij KRii];
C=[1 0 0 0;0 1 0 0];
D=zeros(2,2);

```

```
function [FB,DFB]=spnar(FB,DFB,OsFB,ISE, izpog,iter)
```

```
%-----
%  MODUL: spnar.m
%-----
%  PROGRAM: spnar.m
%-----
%  FUNKCIJA: Postupak samoorganiziranja slobodnih parametara PNAR-a
%-----
%  ULAZNE VARIJABLE:
%  FB=[Fe Be Fde Bde] Podešavaju?i slobodni parametri s obzirom na pogrešku pozicije (e) i brzine (de)
%  DFB=[DFe DBe DFde DBde] Prirasti slobodnih parametara u prethodnom koraku
%  OsFB=[OsFe OsBe OsFde OsBde] - Osjetljivost slobodnih parametara
%  ISE=[ISEe ISEde] - Integrali kvadrata pogreške pozicije i brzine na kraju iterativnog postupka
%  izpog=[e,de] - Izlazna pogreška pozicije i brzine
%  iter - broj iteracije
%-----
%  IZLAZNA VARIJABLA:  FB=[Fe Be Fde Bde] - Nove podešene vrijednosti slobodnih parametara
%                      DFB=[DFe DBe DFde DBde] - Nove vrijednosti prirasta slobodnih parametara
%-----
%
%  Kirola, M. 11-26-2004
%  Napravljeno u Dubrovniku (c), 2003-2005
%-----
```

```
e=izpog(1,1);
de=izpog(1,2);
Fe=FB(1,1);
Be=FB(1,2);
Fde=FB(1,3);
Bde=FB(1,4);
DFe=DFB(1,1);
DBe=DFB(1,2);
DFde=DFB(1,3);
DBde=DFB(1,4);
OsFe=OsFB(1,1);
OsBe=OsFB(1,2);
OsFde=OsFB(1,3);
OsBde=OsFB(1,4);
AFe=0.16;
ABe=0.67;
AFde=0.14;
ABde=0.97;
sigmaFe=8;
sigmaBe=8;
sigmaFde=2;
sigmaBde=2;
ISEep=0.09;
ISEdep=0.81;
alfaFe=0.5;
```

```

alfaBe=0.5;
alfaFde=0.1;
alfaBde=0.1;

if iter>1
    ISEe=ISE(1,1);
    ISEde=ISE(1,2);
    kFe=exp(sigmaFe*(ISEep-ISEe)/ISEep);
    kBe=exp(sigmaBe*(ISEep-ISEe)/ISEep);
    kFde=exp(sigmaFde*(ISEdep-ISEde)/ISEdep);
    kBde=exp(sigmaBde*(ISEdep-ISEde)/ISEdep);
else
    kFe=1;
    kBe=1;
    kFde=1;
    kBde=1;
end

EtaFe=AFe*kFe;
EtaBe=Be^2*ABe*kBe;
EtaFde=AFde*kFde;
EtaBde=Bde^2*ABde*kBde;

%nove vrijednosti prirasta parametara
DFe=OsFe*EtaFe*e+alfaFe*DFe;
DBe=-OsBe*EtaBe*e+alfaBe*DBe;
DFde=OsFde*EtaFde*de+alfaFde*DFde;
DBde=-OsBde*EtaBde*de+alfaBde*DBde;
DFB=[DFe DBe DFde DBde];

%nove vrijednosti parametara
Fe=Fe+DFe;
Be=Be+DBe;
Fde=Fde+DFde;
Bde=Bde+DBde;
FB=[Fe Be Fde Bde];

```

```
function Relfuzzy_izlaz=mknud(FB,np)
```

```
%-----
%  MODUL: mknud.m
%-----
%  PROGRAM: mknud.m
%-----
%  FUNKCIJA: Formiranje Memorijske Kartice Neizrazitog Upravljačkog Djelovanja (MKNUD)
%-----
%  ULAZNE VARIJABLE:  np - broj bitovne diskretizacije podataka
%                      FB=[Fe Be Fde Bde] slobodni parametri dobiveni samoorganiziranjem
%-----
%  IZLAZNA VARIJABLA: Relfuzzy_izlaz=[MKNUD; E; DE] –
%                      formiranje neizrazite relacijske strukture MKNUD-a, pogreske pozicije i brzine
%-----
%
%  Kirola, M. 01-18-2005
%  Napravljeno u Dubrovniku (c), 2003-2005
%-----

% Osnovni parametri MKNUD-a:
PARAMETRI=[FB(1,1) FB(1,2) 0 0.5 0.7 0 0;
            FB(1,3) FB(1,4) 0 0.5 0.7 0 0;
            17 17.2 19 21 31 65 122;
            17 17.2 19 21 31 65 122;
            2.05 2.05 2.05 2.05 2.05 2.05 2.05;
            2.05 2.05 2.05 2.05 2.05 2.05 2.05];

kdigpret=1/(2^np);
de=-1:kdigpret:1;
e=-1:kdigpret:1;
for j=1:size(de,2)
    for k=1:size(e,2)
        u1=e(k);
        if u1==0
            u1=0.0000001;
        end
        u2=de(j);
        if u2==0
            u2=0.0000001;
        end
        IZLAZ=aFLC(u1,u2,PARAMETRI);
        MKNUD(j,k)=IZLAZ(1,5);
    end
end
DE=de;
E=e;
Relfuzzy_izlaz=[MKNUD; E; DE];
save Relfuzzy MKNUD E DE
```

```
function RELFUZZY=aFLC_d(e,de,MKNUD,E_d,DE_d)
```

```
%-----
%  MODUL:  aFLC_d.m
%-----
%  PROGRAM:  aFLC_d.m
%-----
%  FUNKCIJA:  Izracunavanje izlaza iz MKNUD-a i gradijenta pogreške pozicije i brzine
%-----
%  ULAZNE VARIJABLE:   e - pogreška pozicije
%                      de - pogreška brzine
%                      MKNUD - formirana memorijska kartica neizrazitog upravlja?kog djelovanja
%                      E_d - memorijski blok diskretnih vrijednosti pogreške pozicije
%                      DE_d - memorijski blok diskretnih vrijednosti pogreške brzine
%-----
%  IZLAZNA VARIJABLA:  RELFUZZY=[Ydis, Ke , Kde] - Diskretna vrijednost izlaza MKNUD-a i
%                      gradijenti pozicije (Ke) i brzine (Kde)
%-----
%
%  Kirola, M. 02-24-2005
%  Napravljeno u Dubrovniku (c), 2003-2005
%-----
```

```
DE=DE_d;
E=E_d;
n=log( (size(E,2)-1)/2 )/ log (2);
kdigpret=1/(2^n);
IZLAZF=MKNUD;
k=round(abs(e)/kdigpret)*sign(e);
j=round(abs(de)/kdigpret)*sign(de);
Rk=1/kdigpret+1+k;
Rj=1/kdigpret+1+j;
ec=E(Rk);
dec=DE(Rj);
Uc=IZLAZF(Rj,Rk);
Rkn=Rk+sign(e-ec);
Rjn=Rj+sign(de-dec);
ec1=E(Rkn);
dec1=DE(Rjn);
Uec1=IZLAZF(Rj,Rkn);
Udec1=IZLAZF(Rjn,Rk);
Kde=(Udec1-Uc)/(dec1-dec);
Ke=(Uec1-Uc)/(ec1-ec);
ud=-Kde*dec-Ke*ec+Uc;
Y=Kde*de+Ke*e+ud;
RELFUZZY=[Y Ke Kde];
```

```
function [K,H,t]=riccati(A,B,C,Hpoc,ozn,R,Q,pogreska)
```

```
%-----
%  MODUL: riccati.m
%-----
%  PROGRAM: riccati.m
%-----
%  FUNKCIJA: rješavanje nelinearne diferencijalne rikatijske matrične jednačbe, općeg oblika (6.34)
%               $dH=E*H+H*E'-H*F*K'+G*Q*G'$  gdje je  $K'=R^{-1}*F'*H$ , odnosno gdje su
%              za ozn='KF'  $E=A$ ,  $F=C'$  i  $G=B$ ; za ozn='OU'  $E=A'$ ,  $F=B$  i  $G=I$ 
%-----
%  ULAZNE VARIJABLE:
%  A - matrica koeficijenata sustava dim(4x4)
%  B - matrica ulaza sustava dim(4x2)
%  C -matrica izlaza sustava dim(2x4)
%  Hpoc - Pocetna dijagonalna matrica varijanci dim(4x4)
%  ozn - oznaka 'KF' Kalman Busijev Filter ili 'OU' Optimalno Upravljanje
%  R - težinska matrica mjerne smetnje dim(2x2), Q -težinska matrica vanjske smetnje dim(2x2) za 'KF';
%  R - težinska matrica ulaza sustava dim(2x2), Q - težinska matrica stanja sustava dim(4x4) za 'OU'
%-----
%  IZLAZNA VARIJABLA: [K,H,t] - K - Kalmanova pojačanja dim(2x4)
%                      H - rješenje nelinearne diferencijalne matrične Rikatijske jednačbe
%                      t - proteklo vrijeme do dobivene stacionarne (ustaljene) matrice H
%-----
%
%  Kirola, M. 03-25-2005
%  Napravljeno u Dubrovniku (c), 2003-2005
%-----

m=size(B,2);
n=size(A,2);
p=size(C,1);
if isempty(R)==1 & isempty(Q)==1
    if ozn=='OU'
        R=eye(m);
        Q=eye(n);
    elseif ozn=='KF'
        R=eye(p);
        Q=eye(m);
    end
end
t0=0;
tf=100;

%inicijalizacija matrice H
if isempty(Hpoc)==1
    H=eye(n)*0.1;
else
    H=Hpoc;
End
```

%optimalno upravljanje (OU) ili Kalman filter (KF)

if ozn=='OU'

 E=A';

 G=eye(n);

 F=B;

elseif ozn=='KF'

 E=A;

 G=B;

 F=C';

End

Ts=0.001;

i=0;

dH=eye(n);

if isempty(pogreska)==1

 pogreska=0.0001;

end

while abs(sum(sum(dH))) > pogreska

 K=R^(-1)*F'*H;

 dH=E*H+H*E'-H*F*K+G*Q*G';

 H=H+Ts*dH;

 i=i+1;

 if ozn=='KF'

 t=t0+i*Ts;

 elseif ozn=='OU'

 t=tf-i*Ts;

 end

 if t<=0

 disp(' ')

 disp('Povecaj finalno vrijeme tf')

 break

 end

end